

VYSOKÁ ŠKOLA BÁŇSKÁ – TECHNICKÁ UNIVERZITA OSTRAVA
EKONOMICKÁ FAKULTA

KATEDRA FINANČÍ

Modelování volatility vybraných akciových indexů zemí střední Evropy
Volatility Modelling of the Selected Central European Stock Market Indexes

Student: Bc. Michal Mazur
Vedoucí diplomové práce: Ing. Petr Sed'a, Ph.D.

Ostrava 2010

Místopřísežné prohlášení

„Místopřísežně prohlašuji, že jsem celou diplomovou práci včetně všech příloh vypracoval samostatně.“

.....

.....

Bc. Michal Mazur

Obsah

1	Úvod.....	1
2	Charakteristika finančních časových řad	7
2.1	Normalita časových řad	7
2.2	Linearita časových řad.....	9
2.3	Vliv mikrostruktury trhu na vlastnosti časových řad	9
2.4	Volba dat a jejich transformace.....	10
2.5	Manipulace kursů	10
2.6	Stacionarita	11
3	Metody modelování volatility	13
3.1	Testování stacionarity.....	14
3.2	Výstavba modelu volatility.....	15
3.3	Testování podmíněné heteroskedasticity	16
3.4	Lineární modely volatility	17
3.4.1	ARCH modely.....	17
3.4.2	GARCH modely.....	19
3.4.3	IGARCH modely	20
3.4.4	GARCH-M modely	21
3.5	Nelineární modely volatility	22
3.5.1	EGARCH modely	22
3.5.2	QGARCH modely.....	24
3.6	Odhad parametrů.....	24
3.7	Testování vhodnosti modelu	26
3.7.1	Test normality	27
3.7.2	Test autokorelace	27
3.7.3	Test heteroskedasticity	28
3.7.4	Výběr modelu dle informačního kritéria	29
3.8	Předpovědi na další období.....	30
4	Empirická analýza volatility vybraných akciových indexů	32
4.1	Základní charakteristika a vývoj akciových trhů v zemích střední Evropy.....	32
4.1.1	Burzy	32
4.1.2	Burzovní indexy.....	37
4.2	Volba dat a jejich základní statistická analýza.....	43

4.3	Test stacionarity výnosů	48
4.4	Test heteroskedasticity	49
4.5	Odhad lineárního nebo nelineárního modelu volatility	50
4.5.1	Maďarsko	51
4.5.2	Polsko	52
4.5.3	Slovensko	53
4.5.4	ČR	55
4.6	Testování reziduí odhadnutých modelů	56
4.6.1	Testování normality	56
4.6.2	Test autokorelace	61
4.6.3	Test heteroskedasticity	64
4.7	Grafické vyjádření volatility	66
5	Shrnutí výsledků	72
6	Závěr	77
	Seznam použité literatury	81
	Seznam zkratk	83
	Prohlášení o využití výsledků diplomové práce	84
	Přílohy	85

1 Úvod

V posledních letech dochází ke globalizaci finančních trhů. Finanční trhy jsou ovlivňovány globalizací ze dvou základních důvodů. Prvním faktorem je bezesporu liberalizace světového obchodu a devizových režimů, což v podstatě napomáhá k odstranění institucionálních bariér obchodních výměn a kapitálových toků. Druhým faktorem jsou pak finanční inovace, které jsou podporovány vývojem informačních a telekomunikačních technologií a v průběhu posledního desetiletí hrály významnou roli ve snižování nákladů a zvyšování efektivnosti na finančních trzích.

Důsledkem globalizace je pak existence globálních trhů neboli celosvětových trhů, kde lze koupit nebo prodat aktivum za jedinou cenu, tedy cenu stejnou bez ohledu na geografické vzdálenosti a místní okolnosti. Příkladem globálního trhu jsou trhy komoditní, kapitálové a devizové, přičemž je třeba brát v úvahu, že ne každý výše zmíněný trh je trhem globálním. S finanční globalizací souvisí rovněž finanční zprostředkovatelství, měnová stabilita, stabilita finančního systému apod.

Obecně se dá říci, že mezi vyspělými ekonomikami se realizují daleko větší toky než směrem k ostatním zemím. Finanční trhy v rozvinutých ekonomikách jsou efektivnější a investoři zde proto zaměřují více svou pozornost. Finanční globalizace i přes všechna svá pozitiva může negativně ovlivnit situaci na finančních trzích, jelikož zhoršuje a zesiluje dopady rizik, které jsou doprovodným jevem obchodování na těchto trzích.

Charakteristickým znakem finančních inovací je zrychlení obchodních operací, kdy je současně možné téměř okamžitě uskutečnit obchodní operaci a tedy i tento fakt láká investory na finanční trh, kde se investoři zaměřují na modelování a předpovídání budoucího vývoje finančních časových řad ať již kurzů akcií, úrokových sazeb apod.

Správná předpověď budoucího vývoje ceny aktiva přináší vyšší zisk a investoři jsou tak motivováni k neustálému zlepšování metod směřujících k dosažení přesnějších budoucích hodnot. S předpovědí je však spojeno riziko, že tato předpověď nebude správná, existuje zde nestálost, kolísání cen akcií, změny kursů apod. Tato riziková část je vyjádřena v podobě volatility. Tedy čím nižší je volatilita tím menší je riziko, avšak nízké volatilitě odpovídá také nízký výnos. Záleží pak na investorovi a na jeho přístupu k riziku zda toto riziko přijme či nikoliv. Volatilita je tedy velmi důležitým prvkem, který z velké míry ovlivňuje rozhodování investorů.

Zjišťování hodnoty volatility, zejména její predikce je věcí náročnější. Dle teorie efektivních trhů je finanční trh efektivní a adaptuje se téměř okamžitě dle kurzotvorných informací. Teorie efektivních trhů tedy zpochybňuje využívání fundamentálních a technických analýz, které se snaží o budoucí předpověď. I přesto, je však po nových sofistikovaných modelech volatility poptávka, stejně tak jako po nových softwarových produktech, které by napomohly k rychlejšímu a přesnějšímu odhadu kurzu.

Kapitálový trh jako součást finančního trhu je ve srovnání se západní Evropou či Spojenými státy v zemích střední Evropy poměrně nerozvinutý, avšak je na podobné úrovni, co se týče struktury a institucionálního uspořádání. Chování kapitálového trhu v tranzitivních ekonomikách je ovlivněno mimo jiné i vybudovanou strukturou prvků a vazeb mezi jednotlivými státy, se kterými burzy těchto zemí konkurují a zároveň spolupracují. Jedním z prvků tohoto systému jsou investoři, kteří si vybírají adekvátní nástroje a metody, které podporují jejich rozhodovací proces při analýze a sestavení optimálního portfolia aktiv.

Významnou částí kapitálového trhu je akciový trh, který je ovlivňován velkým množstvím politických, ekonomických a psychologických faktorů, mezi nimiž existují jak lineární, tak i nelineární vztahy. Proto se jejich vztahy začali zabývat analytici, kteří se snaží o předpověď chování akciových kursů. Hledají tedy určité vzory, které pak ve výsledku tvoří určitý model, jenž je používán obchodníky a investory.

Předkládaná diplomová práce je tedy věnována problematice testování a modelování volatility akciového trhu v Maďarsku, Polsku, Slovensku a České republice.

Téma předložené diplomové práce bylo zvoleno zejména proto, že se jedná o problematiku aktuální a navíc v České republice je ve srovnání se zahraničím poněkud opomíjeno. Dalším důvodem je záměr analyzovat středoevropský akciový trh, jehož součástí je i trh český.

Cílem předložené diplomové práce je empirická analýza volatility vybraných akciových indexů zemí střední Evropy v období od roku 2004 do roku 2009 pomocí lineárních a nelineárních metod. V práci budou analyzovány denní výnosy hlavních reprezentantů akciových trhů zemí střední Evropy, konkrétně se bude jednat o trh maďarský, polský, slovenský a český.

Z hlavního cíle diplomové práce vycházejí i jednotlivé dílčí cíle, které jsou v práci řešeny:

- a) posouzení vhodnosti využití lineárních a nelineárních modelů volatility,
- b) analýza stability výsledků ve vymezených časových obdobích,
- c) testování asymetrie příchodů nových informací na trh,
- d) testování zda trh oceňuje riziko.

V práci bylo využito systémového přístupu, který je založen na spojení jednotlivých dílčích prvků vzájemnými interakcemi, přičemž nesmí být opomenut žádný důležitý fakt, který by mohl mít na řešení problému podstatný vliv. Na řešenou problematiku musí být nahlíženo komplexně se všemi specifiky.

Metody, které jsou v této diplomové práci použity jsou v souladu s výše uvedeným cílem, k jehož splnění bylo zapotřebí důkladné studium a analýza dostupných tuzemských i zahraničních prací a materiálů. Z těchto zdrojů jsou analyzovány teoretické a praktické otázky modelování volatility. Pro modelování volatility byla použita skupina modelů podmíněné heteroskedasticity ARCH s podmíněným rozptylem.

Při práci s materiály byly využity klasické metody, jako je analýza, tj. podrobný popis jednotlivých pramenů, a následně syntéza, tj. souhrn relevantních dat a získaných informací. V práci je také použita metoda indukce, kdy se na základě porovnání jednotlivých jevů vyvozují všeobecné závěry, metoda dedukce, při níž se vyvozují dílčí závěry z všeobecného platného pravidla, a metoda komparace.

Vzhledem k uvedenému cíli je předložená diplomová práce „Modelování volatility vybraných akciových indexů zemí střední Evropy“ tvořena úvodem, následnými čtyřmi vnitřně členěnými obsahovými kapitolami, závěrem a některými přílohami. Kapitola druhá a třetí tvoří část teoreticko-metodologickou. Kapitola čtvrtá a pátá je pak částí aplikačně-ověřovací.

Kapitola 2 – Charakteristika finančních časových řad

Druhá kapitola je věnována základním charakteristikám a vlastnostem finančních časových řad, kterými je především normalita, linearita a stacionarita. Dále je zde popsán vliv mikrostruktury trhu působícího na vlastnosti časových řad. V závěru kapitoly je přiblížena problematika výběru dat a jejich následné úpravy, stejně tak nebezpečí možné manipulace s kursy, která by mohla ohrozit průhlednost na trhu.

Kapitola 3 – Metody modelování volatility

Třetí kapitola je podrobněji zaměřena na teorii modelování volatility. Je zde tedy podrobně popsána výstavba modelu volatility, která se skládá z několika kroků. Protože je jedním ze základních kroků výběr modelu, jsou v úvodní části popsány jednotlivé nejpoužívanější lineární a nelineární modely, mezi které patří např. ARCH, GARCH, IGARCH, EGARCH a další. Zvláštní pozornost je věnována odhadu parametrů modelu, předpovědi volatility na základě lineárních nebo nelineárních modelů, testování vhodnosti modelu a také podmínkám kladeným na parametry modelu.

Kapitola 4 – Empirická analýza volatility vybraných akciových indexů

Čtvrtá kapitola je stěžejní kapitolou předkládané diplomové práce, jelikož je zaměřena na empirickou analýzu volatility vybraných akciových indexů. Pozornost je věnována maďarské, polské, slovenské a české burze cenných papírů s důrazem na jejich hlavní akciové indexy. V práci pracujeme s časovými řadami logaritmu denních výnosů vybraných indexů za období od 1. 5. 2004 do 31. 12. 2009. U těchto časových řad jsou provedeny diagnostické testy včetně testu stacionarity. Nejdůležitějším bodem této kapitoly je pak odhad nejlepšího lineárního a nelineárního modelu pro jednotlivé časové řady. U těchto odhadů je následně proveden test normality, autokorelace a heteroskedasticity včetně popisů z toho plynoucích závěrů. Na konci kapitoly je graficky a slovně charakterizován průběh volatility zkoumaných časových řad.

Kapitola 5 – Shrnutí výsledků

Pátá kapitola je věnována kompletnímu shrnutí všech výsledků z aplikační části diplomové práce. V kapitole jsou tedy shrnuty všechny kroky, které byly v aplikační části provedeny. Větší pozornost je však věnována výsledkům odhadu modelů volatility, diagnostickým testům, testování asymetrie a vztahu investorů k riziku.

V závěru je celá řešená problematika v rámci této diplomové práce uzavřena a jsou zde zhodnoceny výsledky práce z hlediska cíle práce. V závěrečné kapitole jsou uvedeny také další možnosti rozvoje a řešení daného problému, tedy nastoleny další dílčí otázky a směr, kterým by se mohl další výzkum v této oblasti ubírat.

Veškeré výpočty jsou prováděny v prostředí EViews 6.0, SPSS for Windows 17.0, případně MICROSOFT EXCEL 2007.

2 Charakteristika finančních časových řad

Vzhledem k tomu, že je tato práce věnována modelování volatility, je nutné se podrobněji zaměřit na charakterizaci finančních časových řad. V této kapitole jsou tedy charakterizovány finanční časové řady. Finančními časovými řadami jsou časové řady, které vycházejí z cen, případně ceny a jejich vývoj charakterizují. Specifikem pro finanční časové řady je vysoká časová frekvence jednotlivých hodnot, které jsou nejčastěji zaznamenávány v denní frekvenci.

S vysokou frekvencí zaznamenávání je spjata riziko systematické a nesystematické, které se projevuje v relativně proměnlivé variabilitě jejich vývoje. Ještě je třeba zmínit, že ze složek způsobených faktory systematickými se výrazně projevuje složka trendová a cyklická, sezonní složka není tak zřetelná, i když není možné vyloučit její přítomnost.

U časových řad počítaných s vyšší časovou frekvencí, tedy v případě hodnot, s kterými budeme pracovat, lze sledovat několik charakteristických vlastností jako vyšší špičatost rozdělení pravděpodobností, „tlusté“ konce rozdělení pravděpodobností původních hodnot časových řad, ale i časových řad náhodných chyb. Problematikou vlastností finančních časových řad se zabývali např. Bachelier (1900), Cowles (1993), Fama (1970), Malkiel (1992), Campbell, Lo, MacKinley (1997). Následující podkapitoly budou zaměřeny na jednotlivé vlastnosti finančních časových řad.

2.1 Normalita časových řad

Jedním ze základních předpokladů finančních časových řad je skutečnost, že logaritmy výnosů mají normální rozdělení s konstantní střední hodnotou μ a konstantním rozptylem σ_r^2 . Předpoklad normality se dá tedy zapsat jako $r_t \sim N(\mu, \sigma_r^2)$, kde r_t jsou hodnoty časové řady výnosů, viz Arlt, Arltová (2003). Toto rozdělení je symetrické, což znamená, že jeho šikmost je definována vztahem

$$SK_r = E\left[\frac{(r_t - \mu)^3}{\sigma_r^3}\right], \quad (2.1)$$

je rovna nule. A jeho špičatost je definována vztahem

$$K_r = E\left[\frac{(r_t - \mu)^4}{\sigma_r^4}\right], \quad (2.2)$$

je rovna 3.

Bodovým odhadem šikmosti je výběrová charakteristika

$$\widehat{SK}_r = \frac{1}{T} \sum_{t=1}^T \frac{(r_t - \bar{r})^3}{s_r^3} \quad (2.3)$$

kde

$$\bar{r} = \frac{1}{T} \sum_{t=1}^T r_t, \quad (2.4)$$

$$s_r = \sqrt{\frac{1}{T} \sum_{t=1}^T (r_t - \bar{r})^2}, \quad (2.5)$$

špičatost je pak odhadnuta výběrovou charakteristikou

$$\hat{K}_r = \frac{1}{T} \sum_{t=1}^T \frac{(r_t - \bar{r})^4}{s_r^4}. \quad (2.6)$$

Původní hodnoty časové řady, ale i logaritmy výnosů mají však ve skutečnosti zešikmené rozdělení. Jejich rozdělení je výrazněji špičatější, než je tomu v případě normálního rozdělení. Tyto rozdělení mají obvykle „tlustší“ konce než je tomu u normálního rozdělení, což tedy znamená, že množství výskytů extrémně vysokých kladných nebo záporných výnosů je vyšší, než je předpokladem u normálního rozdělení.

Z důvodu nalezení lepšího rozdělení, které by charakterizovalo lépe vlastnosti finančních časových řad, se začalo využívat tzv. stabilní rozdělení. Do této skupiny patří i normální rozdělení. Pro stabilní rozdělení je charakteristické, že součet náhodných veličin má stejné rozdělení pravděpodobnosti jako jednotlivé náhodné veličiny. Nenormální stabilní rozdělení lépe zachycuje výraznější špičatost a „tlusté“ konce rozdělení četností logaritmů výnosů finančních časových řad. Jejich charakteristickou vlastností je nekonečný rozptyl a momenty řádu vyššího než 2. Výběrový rozptyl a výběrová charakteristika špičatosti dat generovaných nenormálním stabilním rozdělením s rostoucím rozsahem datového souboru nekonvergují, ale naopak rostou do nekonečna. Tento fakt byl příčinou hledání jiného rozdělení, které by vlastnosti finančních časových řad charakterizovalo lépe než normální rozdělení a přitom mělo konečný rozptyl a momenty vyššího řádu. Zde se často uvádí jako možného kandidáta Studentovo t -rozdělení.

2.2 Linearita časových řad

Následující část je věnována problematice linearity časových řad. Klasické analýzy finančních časových řad obvykle předpokládají, že logaritmy výnosů jsou nekorelované stejně rozdělené veličiny s nulovou střední hodnotou a konstantním rozptylem nebo se předpokládá, že jsou nezávislé stejně rozdělené náhodné veličiny s nulovou střední hodnotou a konstantním rozptylem. V případě nekorelovaných logaritmů výnosů se jedná o proces bílého šumu a v případě nezávislých logaritmů výnosů se jedná o striktní proces bílého šumu.

Tyto hypotézy jsou však teoretické a ve skutečnosti dochází k tomu, že střední hodnoty jsou nenulové, tedy podmínka nulové střední hodnoty není dodržena. Stejně tak nebývá dodržena podmínka nekorelovanosti logaritmů výnosů a logaritmy výnosů mohou být tedy lineárně závislé. Tuto lineární závislost je možné vyjádřit pomocí stacionárních lineárních modelů ARMA, které vycházejí z lineárního procesu tvořeného lineární kombinací nekorelovaných stejně rozdělených náhodných veličin, které jsou charakteristické časovou proměnlivostí podmíněné střední hodnoty a konstantní variabilitou, viz Arlt, Arltová (2003).

V případě burzovních indexů a směnných kurzů lze empiricky vysledovat, že variabilita logaritmů výnosů je proměnlivá. Tato variabilita se dále označuje jako volatilita. Pokud dochází k tomu, že se volatilita mění ve velmi krátkých časových úsecích, pak lze některé výnosy považovat za extrémní hodnoty. Na druhé straně se může volatilita měnit zvolna a po určitý čas je na podobné úrovni a pak následně dojde ke změně této úrovně.

S proměnlivou variabilitou bylo zjištěno několik skutečností. První z nich je, že s variabilitou souvisí úroveň a síla autokorelace v časových řadách. Dále bylo zjištěno, že vysoká variabilita obvykle následuje po záporném výnosu. Tyto skutečnosti vycházejí z chování ekonomických subjektů na finančním trhu. Následující kapitola je zaměřena na mikrostrukturu trhu, která má na vlastnosti časových řad rovněž velký vliv.

2.3 Vliv mikrostruktury trhu na vlastnosti časových řad

Vlastnosti finanční časových řad nemusí být determinovány pouze odrazem situací a vztahů na finančních trzích, ale určitou roli zde hraje i mikrostruktura trhu, tedy jakési aspekty organizačního a technického charakteru, které mohou vlastnosti časových řad měnit. Mikrostrukturou trhu se zabývali Arlt, Arltová (2003), Campbell, Lo, MacKinlay (1997), Roll (1984).

Jednou z nejpodstatnějších skutečností měnící vlastnosti časových řad je nesynchronní obchodování. Tento efekt vzniká v případě, kdy se u hodnot časových řad počítá s tím, že jsou

generovány v intervalech stejné délky. Tento předpoklad je však špatný, jelikož například v případě akcií nedochází ke každodennímu obchodování a existují dny, kdy se neobchoduje a neakceptace tohoto jevu může způsobit zdánlivou autokorelaci v časové řadě logaritmu výnosů. Tato autokorelace je způsobena zadržováním informací ve dnech, kdy se neobchoduje.

Důležitou vlastností finančního trhu je likvidita. Je to vlastnost důležitá pro investory, kteří chtějí rychle koupit případně rychle prodat akcie, měnu, komodity atd. Likviditu na finančním trhu zajišťují obchodníci, kteří dle dané nabídky a poptávky nakupují či prodávají. Prodejní a nákupní ceny se však liší a jejich rozdíl komplikuje situaci s finančními časovými řadami stejně tak, jako transakční cena, která se nemusí ztotožňovat s nákupní či prodejní cenou. Proto vzniká otázka, z jaké ceny by se měl počítat výnos.

2.4 Volba dat a jejich transformace

Další otázkou, která musí být řešena, je výběr titulů, které budou analyzovány. Je zřejmé, že se bude jednat o významné akciové tituly obchodované na středoevropském trhu. Kromě toho musí být také rozhodnuto o analyzovaném trhu. Trh se musí přesně vymezit, stejně tak jako burzy, které musí být komparativní, tedy musí být srovnatelné. Co se týká titulů, je jasné, že musí být vybrány takové emise, které umožňují rychlé spekulace. Musí být obchodovány každý den, a to v relativně velkých objemech. V případě této práce jsou zvoleny nejdůležitější burzy středoevropského akciového trhu.

Jiným standardním problémem je volba transformací testovaných ukazatelů. Výběr transformací je v zásadě jen technickým problémem, řešitelným klasickými statistickými nástroji. Například při rozhodování, zda budou testy náhodnosti aplikovány na denní změny kursů (jejich difference) nebo denní výnosy, může být vybrána ta veličina, která lépe splňuje předpoklad homoskedasticity.

2.5 Manipulace kursů

Jiným a zcela specifickým problémem je manipulace kursů. Na vyspělých trzích s vysokou likviditou není nutné brát možnost manipulace vůbec v úvahu, protože manipulace kursem je zde příliš nákladná a proto v podstatě nereálná. Na méně vyspělých trzích je s ní však nutné počítat. Technická analýza ji není schopna bez dodatečných fundamentálních a psychologických informací rozeznat. Možnost manipulace však spolu s nízkou likviditou výrazně zvyšuje spekulantovo riziko. V této práci bude možnost manipulace kursem ignorována. Jedná se o korektní řešení, protože skutečný technický analytik může spekulaci

odhalit také výhradně z kursovních historických dat. Jednotlivé burzy či národní banky tvoří pravidla a omezení pro manipulaci s kursy a „manipulaci kursů“ zařazuje do kategorie „zneužívání trhu“.

Výše byl tento pojem popsán velice obecně a lépe tento pojem přiblíží následující charakteristika. Manipulace kursů je tedy jednání, které je způsobilé zkreslit představu účastníků kapitálového trhu o hodnotě investičního instrumentu, jenž je nebo má být přijat k obchodování na veřejném trhu, o nabídce tohoto instrumentu nebo poptávce po něm, anebo jiným způsobem deformovat kurs tohoto instrumentu. Za manipulace je vždy odpovědný obchodník, který má zajistit průhlednost trhu a má znát záměry zákazníka. Více informací o této problematice lze nalézt na webových stránkách České národní banky (www.cnb.cz), kde jsou mimo jiné doporučení pro obezřetné chování obchodníků a příklady možných kursových manipulací.

2.6 Stacionarita

Pro aplikaci standardní regresní analýzy je nutné zamítnout hypotézu nestacionarity výnosů, jinými slovy, nutnou podmínkou aplikace těchto modelů je stacionarita výnosů. Stacionarita je důležitým předpokladem nejen pro regresní analýzu, ale také pro kvalitu predikce časové řady. Dále je nutné zmínit, že pokud není stochastický proces generující konkrétní výběr T pozorování časové řady v čase stabilní, neboli není konzistentní s budoucími skutečnými hodnotami predikované náhodné veličiny, nelze očekávat, že předpovědi, získané na základě informace o jejím chování v minulosti, budou reálné.

Se stacionaritou je úzce spojen pojem stochastický proces, což je v čase uspořádaná řada veličin $\{X(s, t), s \in S, t \in T\}$, kde S je výběrový prostor a T je indexní řada.

Stochastický proces se nazývá striktně stacionární, jestliže pro jakoukoliv indexní část (t_1, t_2, \dots, t_n) z $T = \{0, \pm 1, \pm 2, \dots\}$ a jakékoliv reálné číslo k , pro které $t_i + k \in T, i = 1, 2, \dots, n$, platí

$$F(X_{t_1}, X_{t_2}, \dots, X_{t_n}) = F(X_{t_1+k}, X_{t_2+k}, \dots, X_{t_n+k}),$$

kde $F(\cdot)$ je sdružená distribuční funkce. Striktní stacionární řada tedy říká, že pravděpodobnostní chování daného stochastického procesu je časově invariantní.

Stochastický proces se označuje jako normální nebo gaussovský, jestliže jeho sdružené pravděpodobnostní rozdělení je normální. Tedy v takovém případě by pojem striktní a slabá stacionarita znamenal totéž. Většina výsledků pak vychází většinou z gaussovskeho rozdělení.

V případě stacionárního stochastického procesu $\{X_t\}$ lze vyjádřit autokovarianční funkci mezi veličinami X_t a X_{t-k} jako

$$\gamma_k = C(X_t, X_{t-k}) = E(X_t - \mu)(X_{t-k} - \mu), \quad (2.7)$$

a autokorelační funkci jako

$$\rho_k = \frac{C(X_t - X_{t-k})}{\sqrt{D(X_t)}\sqrt{D(X_{t-k})}} = \frac{\gamma_k}{\gamma_0}, \quad (2.8)$$

kde vzhledem ke stacionaritě procesu $D(X_t) = D(X_{t-k}) = \gamma_0$. Autokorelační funkce se označuje jako ACF.

Tato autokorelační funkce má následující vlastnosti:

- a) $\rho_1 = 0$,
- b) $|\gamma_k| \leq \gamma_0$; $|\rho_k| \leq 1$,
- c) $\gamma_k = \gamma_{-k}$ a $\rho_k = \rho_{-k}$ pro všechna k , autokovarianční a autokorelační funkce je tedy symetrická kolem $k = 0$. Tato vlastnost vyplývá ze skutečnosti, že časová vzdálenost dvojic veličin X_t, X_{t+k} a X_{t-k}, X_t je stejná. Z tohoto důvodu je autokorelační funkce vyjadřována pouze pro $k > 0$. Grafem autokorelační funkce je korelogram.

Korelace mezi dvěma náhodnými veličinami je často způsobena tím, že obě tyto veličiny jsou korelovány s veličinou třetí. Parciální autokorelace podávají pak informace o korelaci veličin X_t, X_{t+k} očištěné o vliv veličin ležících mezi nimi. Podrobněji se této problematice věnuje Arlt (1999).

Z tohoto vyplývá, že ze statistického hlediska může existovat řada stacionární, u které nejsme schopni na základě zjištěných statistických parametrů, jako jsou průměr a rozptyl, resp. kovariance, schopni odlišit jeden úsek řady od druhého, a řada nestacionární, která vykazuje změny v chování. V této práci se pracuje s vysokofrekvenčními časovými řadami a výnosy, takže finanční časové řady budou vždy stacionární.

Při zjišťování stacionarity se pracuje s modely AR, MA, ARMA, které jsou charakteristické specifickou formou autokorelační funkce a parciální autokorelační funkce, a jejich odhady lze použít při identifikaci modelu konkrétních analyzovaných časových řad.

3 Metody modelování volatility

V současnosti dochází k růstu zájmu o modelování ekonomických časových řad, a to zejména finančních časových řad, které obsahují data za velmi krátké časové intervaly.

Výnosy na finančních trzích jsou ovlivňovány především rizikem, přičemž významnou roli hraje vztah rizika a výnosu. Z tohoto důvodu je měření rizika velmi důležitou charakteristikou finančních instrumentů, které je nejběžněji vyjádřené prostřednictvím volatility. Pro modelování volatility je tedy důležité definovat samotný pojem „**volatilita**“ a postup jejího odhadu, který se provádí na základě lineárních nebo nelineárních modelů volatility.

S potřebou měřit volatilitu výnosů finančních instrumentů se lze setkat nejen ve finanční teorii, ale zejména v praxi. Dle Markowitze (1952) se riziko jednoho aktiva vyjadřuje jako rozptyl výnosů či směrodatná odchylka výnosů neboli volatilita. **Volatilitou pak rozumíme nestálost, kolísání výnosových měr, měnových kurzů anebo cen investičních instrumentů.** Čím vyšší je volatilita cenného papíru, tím větší je riziko ztráty. Z tohoto důvodu je volatilita velmi důležitým parametrem v oblasti financí a její zkoumání je klíčové pro rozhodování zejména investorů, kteří se na základě výše rizika rozhodují, zda investovat či nikoliv.

Volatilita je důležitá ve financích z několika důvodů:

- ovlivňuje výši pravděpodobných budoucích výnosů,
- slouží k odhadu intervalu budoucích výnosů,
- může být použita pro hodnocení výkonnosti portfolií,
- slouží k oceňování opcí,
- použití volatility nám umožní lépe pochopit vliv rizika inflace a rizika kolísání cizích měn.

Výpočet volatility je možný zejména na základě:

- a) historického přístupu, tedy zjištění volatility vypočtené na základě historických dat neboli ex-post,
- b) přístupu „implied volatility“, u nějž implikovaná volatilita označuje trhem očekávanou volatilitu do budoucna tedy ex-ante; od implikované volatility se pak odvíjí např. tržní cena opce.

Dle Štěrbý (2007) má volatilita několik základních vlastností:

- a) Stochastický charakter volatility, který znamená, že většinou stanovené předpoklady o konstantní volatilitě neodpovídají skutečnosti.
- b) Volatilita v dlouhém období osciluje kolem svého dlouhodobého průměru. Všechny dlouhodobé předpovědi volatility by tedy měly konvergovat ke své dlouhodobé průměrné hodnotě (angl. mean reversion).
- c) „Tlusté konce“ neboli z angl. „fat tails“, které jsou vlastností výnosů finančního instrumentu, kdy se u nepodmíněné pravděpodobnosti rozdělení výnosů předpokládá tlustší konce než v případě normálního rozdělení. Z tohoto pak vyplývá, že bude docházet k extrémním pohybům cen aktiv častěji než v případě normálního rozdělení.
- d) Shlukování volatility, z angl. „volatility clustering“, představuje skutečnost, že velké změny cen aktiv jsou obvykle následovány dalšími velkými změnami cen aktiv a malé změny cen aktiv jsou následovány malými změnami cen aktiv. Lze tedy říci, že se volatilita shlukuje v čase.
- e) Asymetrický vliv na nové informace, kdy například negativní cenový šok vede k větší volatilitě než pozitivní šok stejné velikosti. Souvisí to se skutečností, že velké množství finančních instrumentů, zejména akcie a burzovní indexy, má negativně zešikmené rozdělení výnosů. Toto zešikmení jsou schopny zachytit pouze nelineární modely volatility.

V následujících podkapitolách bude popsán celý proces modelování volatility, nejvýznamnější lineární a nelineární modely volatility, dále bude popsán odhad modelu volatility, způsoby testování vhodnosti modelu a předpověď na další období.

3.1 Testování stacionarity

Pro zdárné modelování volatility finančních časových řad je nejdříve nutné provést test stacionarity časových řad, se kterými se bude pracovat. Stacionaritu je možné testovat pomocí několika testů, mezi něž patří např. Dickey-Fullerův test jednotkového kořene, Phillips-Perronův test, Kwiatkowski-Phillips-Shmidt-Shinův test, Ng-Perronův test, viz Arlt, Arltová (2003).

Blíže se tedy zaměříme na rozšířený Dickey-Fullerův (ADF) test. U tohoto testu se vychází z procesu

$$X_t = \phi_1 X_{t-1} + \alpha_t \quad (3.1)$$

Nulová hypotéza může být zapsána jako

$H_0 : \phi_1 = \phi_1^{(r)}$, kdy pro $|\phi_1^{(r)}| < 1$ platí, že testové kritérium

$$t = \frac{\hat{\phi}_1 - \phi_1^{(r)}}{S_{\hat{\phi}_1}}, \quad (3.2)$$

kde $S_{\hat{\phi}_1}$ je odhad směrodatné chyby odhadu $\hat{\phi}_1$, má asymptoticky normované normální rozdělení. V případě, kdy $\phi_1^{(r)} = 1$, však toto neplatí a rozdělení statistiky t není asymptoticky normální ani symetrické.

Překročí-li hodnota Dickey-Fullerova testu kritickou hodnotu, zamítáme hypotézu jednotkovosti kořene, a tedy i nestacionarity řady. Tento test ukazuje, že v případě nulové hypotézy jednotkovosti kořene tato statistika nesleduje tradiční Studentovo t-rozdělení, odvozuje asymptotické výsledky a simuluje kritické hodnoty pro různé typy testů a výběrů.

Problematikou jednotkovosti kořene se zabývali kromě Dickey, Fullera (1981), také Kwiatkowski, Phillips, Schmidt, Shin (1992), Campbell, Lo, MacKinley (1997) a další.

3.2 Výstavba modelu volatility

V této podkapitole bude popsán proces tvorby lineárního nebo nelineárního modelu. Proces výstavby těchto modelů je tvořen těmito kroky, viz Arlt, Arltová (2003):

1. Pro danou časovou řadu určit vhodný lineární nebo nelineární úrovnový model.
2. Otestovat nulovou hypotézu podmíněné homoskedasticity proti alternativní hypotéze podmíněné heteroskedasticity lineárního nebo nelineárního typu.
3. Odhadnout parametry zvoleného lineárního nebo nelineárního modelu podmíněné heteroskedasticity.
4. Ověřit vhodnost daného modelu diagnostickými testy.
5. Je-li třeba, modifikovat model.
6. Použít model pro popisné nebo predikční účely.

Krok první je spojen s odhadem nejmenších čtverců, což je metoda pro odhad parametrů regresní funkce u modelů, jež jsou lineární v parametrech. Metoda je založena na minimalizaci součtu čtverců reziduí. Následně obdržíme soustavu rovnic, jejichž řešením získáme konkrétní hodnoty parametrů. Druhý krok je dále popsán v kapitole 3.3 a krok třetí,

tedy odhad parametrů je popsán v kapitole 3.4 až 3.6, kde jsou rovněž charakterizovány jednotlivé modely volatility lineárního a nelineárního typu. Kapitola 3.7 bude věnována kroku čtvrtému tedy ověření vhodnosti daného modelu. Krok šestý pak bude popsán v kapitole 3.8.

3.3 Testování podmíněné heteroskedasticity

Druhým krokem nutným pro výstavbu modelu volatility je testování podmíněné heteroskedasticity, to však může být dvojího typu buď v lineárních řadách, nebo v řadách nelineárních.

Test podmíněné heteroskedasticity v případě lineárního typu, který je založený na principu Lagrangeových multiplikátorů (LM) a který vychází z formulace modelu ARCH, tedy modelu s autoregresní podmíněnou heteroskedasticitou, jenž vytvořil Engle (1982). Je zřejmé, že podmíněný rozptyl h_t modelu ARCH(q) je konstantní, jestliže jsou parametry odpovídající veličinám $\varepsilon_{t-1}^2, \dots, \varepsilon_{t-q}^2$ rovny nule. Nulová hypotéza, tj. hypotéza podmíněné homoskedasticity, je $H_0 : \alpha_1 = \alpha_2 = \dots = \alpha_q = 0$, alternativní hypotézou je, že alespoň jeden parametr je různý od nuly, tj. $H_1 : \text{non } H_0$. Test spočívá v těchto krocích:

1. Odhadnou se parametry lineárního nebo nelineárního úrovnového modelu a získají se rezidua $\hat{\varepsilon}_t^2$ a reziduální součet čtverců ESS_0 .
2. Konstruuje se regresní model, na jehož základě se získá reziduální součet čtverců ESS_1 a index determinace.
3. Testové kritérium LM ve tvaru TR^2 má za předpokladu platnosti nulové hypotézy asymptoticky rozdělení $\chi^2(q)$.
4. Provádí se F-verze tohoto testového kritéria pro malé výběry a je vyjádřen vztahem

$$5. \quad F_{LM} = \frac{\left(\frac{ESS_0 - ESS_1}{q} \right)}{\frac{ESS_1}{T - q - 1}}, \quad (3.3)$$

její rozdělení lze za předpokladu platnosti nulové hypotézy aproximovat rozdělením $F(q, T - q - 1)$.

Tento test se označuje jako ARCH test a Lee (1991) ukázal, že je identický s testem vycházejícím z formulace modelu GARCH(p,q).

Co se týče testování podmíněné heteroskedasticity u nelineárního typu, tak zde existují dvě strategie pro testování přítomnosti podmíněné heteroskedasticity nelineárního typu. První spočívá v tom, že se nejdříve volí lineární model volatility, odhadnou se jeho parametry a následně se zkoumá, zda je tento model vhodný či zda by bylo lepší vzhledem k datovým symetriím použít nějaký model nelineární. Druhá varianta je analogií ověřování podmíněné heteroskedasticity lineárního typu, kde se přímo testuje hypotéza podmíněné homoskedasticity proti hypotéze podmíněné heteroskedasticity nelineárního typu. Problematikou ověřování vlivu kladných a záporných výnosů na podmíněnou heteroskedasticitu se zabýval, Engle a Ng (1993).

3.4 Lineární modely volatility

První modely volatility popsal, Engle (1982) a charakterizoval je tím, že podmíněný rozptyl je lineární funkcí veličin $\varepsilon_{t-1}^2, \varepsilon_{t-2}^2, \dots, \varepsilon_{t-q}^2$, proto se tyto modely a modely z nich odvozené nazývají lineární modely volatility. V následujících podkapitolách budou popsány jednotlivé lineární modely. Je třeba podotknout, že se nejedná o všechny lineární modely, ale pouze o výběr těch nejčastěji používaných, které mají zásadní význam při určování volatility. Lineární modely popisují ve svých publikacích Arlt, Arltová (2003), Campbell, Lo, MacKinley (1997) a Rublíková (2008).

3.4.1 ARCH modely

Je prvotním lineárním modelem, ze kterého je většina dalších modelů odvozena. Jedná se o model s autoregresní podmíněnou heteroskedasticitou, který je charakteristický tím, že pomocí něj lze zachytit shluky volatility v časově řadě výnosů. Tvůrcem modelu je Engle (1982).

Prvním modelem je ARCH (1), který má podmíněný rozptyl ve tvaru

$$h_t = \omega + \alpha_1 \varepsilon_{t-1}^2. \quad (3.4)$$

Podmíněný rozptyl musí být kladné číslo, tedy musí platit podmínka, že $\omega > 0$ a $\alpha_1 \geq 0$. V případě, že $\alpha_1 = 0$ je podmíněný rozptyl v čase konstantní a proces $\{\varepsilon_t\}$ se označuje za podmíněně heteroskedastický.

Autoregresní tvar modelu pak vypadá následovně

$$\varepsilon_t^2 = \omega + \alpha_1 \varepsilon_{t-1}^2 + v_t, \quad (3.5)$$

kde $v_t = \varepsilon_t^2 - h_t = h_t(\varepsilon_t^2 - 1)$. Podmíněná a nepodmíněná střední hodnota procesu $\{v_t\}$ je nulová, což znamená, že proces není autokorelovaný.

O ARCH (1) můžeme říci, že je stacionární v kovariancích, jestliže $\alpha_1 < 1$, dále nepodmíněná střední hodnota procesu $\{\varepsilon_t^2\}$, tj. nepodmíněný rozptyl procesu $\{\varepsilon_t\}$, má tvar

$$D(\varepsilon_t) = \frac{\omega}{1 - \alpha_1}, \quad (3.6)$$

což znamená, že je konstantní v čase a proces $\{\varepsilon_t\}$ je nepodmíněně homoskedastický, autokorelační funkce je ve zpoždění k rovna α_1^k .

Pokud bude absolutní hodnota vysoká, pak se dá předpokládat, že i absolutní hodnota ε_t bude vysoká. Tento model umožňuje lépe zachytit vyšší špičatost pravděpodobnostního rozdělení výnosů. Špičatost náhodných veličin ε_t má pro $3\alpha_1^2 < 1$ tvar

$$K_\varepsilon = \frac{E(\varepsilon_t^4)}{E(\varepsilon_t^2)^2} = \frac{3(1 - \alpha_1^2)}{1 - 3\alpha_1^2}, \quad (3.7)$$

jinak je nekonečná. Špičatost K_ε je tedy vždy větší než špičatost normálního rozdělení.

Dalším modelem typu ARCH je obecný model ARCH (q), jehož podmíněný rozptyl má formu

$$h_t = \omega + \alpha_1 \varepsilon_{t-1}^2 + \alpha_2 \varepsilon_{t-2}^2 + \dots + \alpha_q \varepsilon_{t-q}^2. \quad (3.8)$$

Opět zde platí, že podmíněný rozptyl musí být kladné číslo, tedy musí platit podmínka $\omega > 0$ a $\alpha_i \geq 0$ pro $i = 1, 2, \dots, q$.

Autoregresní tvar modelu pak vypadá následovně

$$\varepsilon_t^2 = \omega + \alpha_1 \varepsilon_{t-1}^2 + \alpha_2 \varepsilon_{t-2}^2 + \dots + \alpha_q \varepsilon_{t-q}^2 + v_t. \quad (3.8)$$

Nepodmíněný rozptyl procesu $\{\varepsilon_t\}$, má tvar

$$D(\varepsilon_t) = \frac{\omega}{1 - \alpha_1 - \alpha_2 - \dots - \alpha_q}, \quad (3.10)$$

což znamená, že je konstantní v čase a proces $\{\varepsilon_t\}$ je nepodmíněně homoskedastický.

3.4.2 GARCH modely

Dalším lineárním modelem je model GARCH, který je označován jako zobecněný ARCH model. V některých situacích je třeba při modelování finančních časových řad použít modely ARCH s vysokým q . S tímto však nastává problém s odhadováním velkého množství parametrů a dalšími omezujícími podmínkami jako stacionarita atd. Modely GARCH se pak vyhýbají těmto problémům, jelikož jsou rozšířením ARCH modelu o zpožděný podmíněný rozptyl, viz Bollerslev (1986).

V případě rozšíření modelu ARCH (1) o podmíněný rozptyl v prvním zpoždění má model podmíněného rozptylu tvar

$$h_t = \omega + \alpha_1 \varepsilon_{t-1}^2 + \beta_1 h_{t-1} \quad (3.11)$$

Podmíněný rozptyl musí být kladné číslo, tedy musí platit podmínka $\omega > 0$, $\alpha_1 > 0$ a $\beta_1 \geq 0$.

Takovýto model se pak označuje jako GARCH(1,1).

Nepodmíněný rozptyl procesu $\{\varepsilon_t\}$ má formu

$$D(\varepsilon_t) = \frac{\omega}{1 - \alpha_1 - \beta_1}, \quad (3.12)$$

což znamená, že je konstantní v čase a proces $\{\varepsilon_t\}$ je nepodmíněně homoskedastický.

Špičatost náhodných veličin ε_t má pro $3\alpha_1^2 + 2\alpha_1\beta_1 + \beta_1^2 < 1$ tvar

$$K_\varepsilon = \frac{E(\varepsilon_t^4)}{E(\varepsilon_t^2)^2} = \frac{3(1 - (\alpha_1 + \beta_1)^2)}{1 - (\alpha_1 + \beta_1)^2 - 2\alpha_1^2}, \quad (3.13)$$

jinak je nekonečná. Špičatost v tomto případě je větší než špičatost normálního rozdělení.

Autokorelační funkce procesu $\{\varepsilon_t^2\}$ je

$$\rho_1 = \alpha_1 + \frac{\alpha_1^2 \beta_1}{1 - 2\alpha_1\beta_1 - \beta_1^2}, \quad (3.14)$$

$$\rho_k = (\alpha_1 + \beta_1)^{k-1} \rho_1, \quad (3.15)$$

kde $k = 2, 3, \dots, n$.

Hodnoty autokorelační funkce s rostoucím zpožděním klesají. Rychlost tohoto poklesu záleží zejména na součtu $\alpha_1 + \beta_1$. Pokud se tento součet blíží hodnotě jedna, pak je pokles autokorelační funkce pozvolný. Hodnoty PACF rovněž s rostoucím zpožděním klesají. Obecný model ze skupiny GARCH je označován jako GARCH(p, q) a jeho podmíněný rozptyl lze zapsat jako

$$h_t = \omega + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{i=1}^p \beta_i h_{t-i} . \quad (3.16)$$

I zde platí podmínka kladného podmíněného rozptylu $\omega > 0$, $\alpha_i > 0$ a $\beta_i \geq 0$.

Nepodmíněný rozptyl procesu $\{\varepsilon_t\}$ je

$$D(\varepsilon_t) = \frac{\omega}{1 - \alpha(1) - \beta(1)} . \quad (3.17)$$

3.4.3 IGARCH modely

Patří mezi lineární modely, které se označují jako integrované GARCH modely, tedy modely upravené o restriktivní podmínku $\alpha_1 + \beta_1 = 1$, což je způsobeno skutečností, že u finančních časových řad se velmi často stává, že součet odhadů parametrů alfa a beta jsou blízké jedné. Konkrétní tvar procesu $\{\varepsilon_t^2\}$ je

$$\varepsilon_t^2 = \omega + \varepsilon_{t-1}^2 + v_t - \beta_1 v_{t-1} . \quad (3.18)$$

Tento proces není stacionární v kovariancích, avšak může být stacionární striktně. Autoři modelu Engle a Bollerslev (1986) model považují za perzistentní v rozptylu tehdy, jestliže dlouhodobá předpověď podmíněného rozptylu ve všech horizontech zůstává citlivá na počáteční podmínky. Autokorelační funkce pak exponenciálně klesá.

Proces IGARCH(p, q) lze vyjádřit jako

$$(1 - \alpha(B) - \beta(B))\varepsilon_t^2 = \omega + (1 - \beta(B))v_t , \quad (3.19)$$

kde $v_t = \varepsilon_t^2 - h_t$ a $(1 - \alpha(B) - \beta(B)) \equiv \phi(B)(1 - B)$, kde kořeny polynomiální rovnice $\phi(B) = 0$, stejně jako kořeny polynomiální rovnice $(1 - \beta(B)) = 0$, leží vně jednotkového kruhu.

Tvar modelu IGARCH(p, q) je tedy

$$\phi(B)(1 - B)\varepsilon_t^2 = \omega + (1 - \beta(B))v_t . \quad (3.20)$$

3.4.4 GARCH-M modely

Posledním popisovaným lineárním modelem je GARCH-M model, který je založen na skutečnosti, že během modelování finančních časových řad může dojít k situaci, kdy úroveň a variabilita výnosů na sobě závisí. Tento model tedy řeší otázku, zda je výnos v hlavní rovnici závislý i na podmíněném rozptylu. Do hlavní regresní rovnice je přidán regresor v podobě směrodatné odchylky nebo rozptylu. V případě že by bylo zjištěno, že výnos je závislý na podmíněné varianci, pak by bylo možné učinit závěr, že trh nějakým způsobem oceňuje riziko. Vztah zachycující model GARCH-M rozšířený o člen charakterizující podmíněný rozptyl má tvar

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + \delta g(h_t) + \varepsilon_t, \quad (3.21)$$

kde $g(h_t)$ je nějaká funkce podmíněného rozptylu procesu $\{e_t\}$ a podmíněný rozptyl h_t se řídí modelem GARCH. Velmi často se předpokládá, že $g(h_t) = h_t$ nebo $g(h_t) = \sqrt{h_t}$. Jestliže $p = 0$ a $g(h_t) = h_t \sim \text{ARCH}(1)$, lze model zapsat ve tvaru

$$X_t = \delta h_t + \varepsilon_t, \quad h_t = \omega + \alpha_1 \varepsilon_{t-1}^2. \quad (3.22)$$

S touto teorií přišli Engle, Lilien a Robins (1987).

Nepodmíněná střední hodnota má tvar

$$E(X_t) = \delta \omega \left(1 + \frac{\alpha_1}{1 - \alpha_1} \right) \quad (3.23)$$

a nepodmíněný rozptyl má tvar

$$D(X_t) = \frac{\omega}{1 - \alpha_1} + \frac{(\delta \alpha_1)^2 2\omega^2}{(1 - \alpha_1)^2 (1 - 3\alpha_1^2)}. \quad (3.24)$$

Nepodmíněná střední hodnota je v tomto případě různá od nuly a nepodmíněný rozptyl je vyšší, než je tomu u modelů bez členů zahrnující podmíněný rozptyl.

Autokorelační funkce má pak tvar

$$\rho_1 = \frac{2\alpha_1^3 \delta^2 \omega}{2\alpha_1^2 \delta^2 \omega + (1 - \alpha_1) + (1 - 3\alpha_1^2)}. \quad (3.25)$$


$$\rho_k = \alpha_1^{k-1} \rho_1, \quad k = 2, 3, \dots \quad (3.26)$$

Lze tedy říci, že autokorelační funkce je závislá na parametru α_1 procesu ARCH(1) a její pokles je exponenciální, viz Rublíková (2008).

3.5 Nelineární modely volatility

Vedle lineárních modelů volatility existují nelineární modely, které zohledňují některé nedostatky modelů lineárních. Základní myšlenkou u nelineárních modelů volatility je tzv. pákový efekt viz Black (1976), což v podstatě znamená, že se kladné i záporné šoky se nepromítají symetricky do podmíněného rozptylu, jak se to předpokládalo u modelů lineárních, viz graf 3.1. Tuto asymetričnost se zatím komplexně nepodařilo vysvětlit. U lineárních modelů nemůže dojít k reflektování této asymetričnosti, jelikož se u nich počítá s čtverci šoků a tudíž mají kladné i záporné šoky stejný efekt. Tento nedostatek řeší modely nelineární a plní tak účel, pro který byly navrženy. Nelineární modely zkoumal a popisoval, Engle, Ng (1993), Pagan, Schwert (1990), Arlt, Arltová (2003), Campbell, Lo, MacKinley (1997) a Rublíková (2008). V následujících podkapitolách budou tedy popsány různé nelineární modely volatility, které se liší zejména různými podobami zachycení efektu kladných a záporných šoků.

Graf 3.1 Křivka účinků asymetrických zpráv



3.5.1 EGARCH modely

Jedná se první model volatility, u kterého bylo možné zachytit asymetrický efekt, viz Nelson (1991). Jedná se o model exponenciální GARCH model, jehož podmíněný rozptyl má tvar

$$\ln(h_t) = \omega + g(\varepsilon_{t-1}) + \beta_1 \ln(h_{t-1}), \quad (3.27)$$

kde

$$g(\varepsilon_{t-1}) = \alpha_1 \varepsilon_{t-1} + \gamma_1 (|\varepsilon_{t-1}| - E(|\varepsilon_{t-1}|)). \quad (3.28)$$

Jelikož model EGARCH popisuje vztah mezi logaritmem podmíněného rozptylu a minulými šoky, není třeba aplikovat žádná omezení na parametry $\alpha_1, \beta_1, \gamma_1$, která by zajišťovala nezápornost podmíněného rozptylu. Z vlastností procesu $\{e_t\}$ vyplývá, že proces $\{g(e_t)\}$ má nulovou střední hodnotu a není autokorelovaný.

Zachycení asymetrie je možné ze vztahu podmíněného rozptylu a šoků, což vyplývá z funkce $g(e_t)$ ve tvaru

$$g(e_t) = (\alpha_1 + \gamma_1)e_t I(e_t > 0) + (\alpha_1 - \gamma_1)e_t I(e_t < 0) - \gamma_1 E(|e_{t-1}|), \quad (3.29)$$

kde $I(A)$ je funkce, která nabývá hodnoty 1, jestliže jev A nastane, a hodnoty 0, jestliže nenastane. Vliv kladných šoků na logaritmus podmíněného rozptylu je dán součtem parametrů $(\alpha_1 + \gamma_1)$ a vliv záporných šoků je dán rozdílem parametrů $(\alpha_1 - \gamma_1)$. To tedy znamená, že pro $(\alpha_1 < 0)$ se zvýší vliv záporného šoku v budoucím podmíněném rozptylu ve srovnání s vlivem šoku kladného.

K měření toho jak se nová informace promítá do volatility modelu, resp. ukazuje vztah mezi šokem ε_t a podmíněným rozptylem h_{t+1} za předpokladu, že ostatní minulé a přítomné informace jsou konstantní, se používá křivka dopadu novinek (NIC), jejíž grafické vyjádření je zobrazeno v grafu 3.1.

Funkce NIC modelu EGARCH(1,1) má pak tvar

$$NIC(\varepsilon_t | h_t = \sigma_\varepsilon^2) = \begin{cases} A \exp\left(\frac{\alpha_1 + \gamma_1}{\sigma_\varepsilon} \varepsilon_t\right) & \text{pro } \varepsilon_t > 0, \\ A \exp\left(\frac{\alpha_1 - \gamma_1}{\sigma_\varepsilon} \varepsilon_t\right) & \text{pro } \varepsilon_t < 0, \end{cases} \quad (3.30)$$

$$\text{kde } A = \sigma_\varepsilon^{2\beta_1} \exp\left(\omega - \gamma_1 \sqrt{\frac{2}{\pi}}\right). \quad (3.31)$$

NIC modelu EGARCH(1,1) je pro parametrizaci $(\alpha_1 < 0)$, $0 \leq \gamma_1 < 1$ a $\beta_1 + \gamma_1 < 1$ nesymetrická, záporné šoky se do budoucího podmíněného rozptylu promítají výrazněji než šoky.

Obecný model EGARCH(p, q) lze vyjádřit ve tvaru

$$(1 - \beta(B)) \ln(h_t) = \omega + (1 + \varphi(B))g(e_{t-1}), \quad (3.32)$$

$$\text{kde } \beta(B) = \sum_{i=1}^p \beta_i B^i, \quad \varphi(B) = \sum_{i=1}^q \varphi_i B^i \text{ a } g(e_{t-1}) = \alpha_1 e_{t-1} + \gamma(|e_{t-1}| - E(|e_{t-1}|)). \quad (3.33)$$

3.5.2 QGARCH modely

Jedná se o rozšířený GARCH model, kde byl rozšířen Sentanou (1995) a je zde navíc člen, který zachycuje přímo vliv šoku ε_t

QARCH(1,1), což je vlastně modifikovaná verze GARCH(1,1) vypadá následovně

$$h_t = \omega + \gamma_1 \varepsilon_{t-1} + \alpha_1 \varepsilon_{t-1}^2 + \beta_1 h_{t-1} = \omega + \left(\frac{\gamma_1}{\varepsilon_{t-1}} + \alpha_1 \right) \varepsilon_{t-1}^2 + \beta_1 h_{t-1}. \quad (3.34)$$

Vliv ε_{t-1}^2 na podmíněný rozptyl h_t je dán vztahem $\frac{\gamma_1}{\varepsilon_{t-1}} + \alpha_1$. Jestliže je $\gamma_1 < 0$, je vliv

záporného šoku na podmíněný rozptyl větší než vliv šoku kladného.

Nepodmíněný rozptyl je stejný jako nepodmíněný rozptyl procesu GARCH(1,1). Podmínky stacionarity v kovariancích a existence špičatosti u tohoto modelu jsou rovněž stejné.

Špičatost náhodných veličin ε_t má pro $3\alpha_1^2 + 2\alpha_1\beta_1 + \beta_1^2 < 1$ tvar

$$K_\varepsilon = \frac{3 \left(1 - (\alpha_1 + \beta_1)^2 + \gamma_1^2 \frac{1 - \alpha_1 - \beta_1}{\omega} \right)}{1 - (\alpha_1 + \beta_1)^2 - 2\alpha_1^2}, \quad (3.35)$$

jinak je nekonečná. Špičatost je v modelu QGARCH je vyšší než v modelu GARCH v případě, že parametry α_1 a β_1 obou modelů jsou stejné a parametr $\gamma_1 \neq 0$.

3.6 Odhad parametrů

Pro vytvoření modelu je nutné odhadnout parametry modely, které dále slouží k výpočtu a testování. Obvyklý model výnosů finančních časových řad se skládá z lineární či nelineárního modelu úrovně časové řady a lineárního nebo nelineárního modelu volatility časové řady.

Takovýto model lze zapsat ve tvaru

$$X_t = G(X_t, \eta) + \varepsilon_t, \quad (3.36)$$

kde $X_t = (1, X_{t-1}, \dots, X_{t-p})'$, $G(X_t, \eta)$ je skeleton lineárního nebo nelineárního autoregresního modelu s parametry η , který je minimálně dvakrát spojitě derivovatelnou funkcí vzhledem

k těmto parametrům h_t typu lineárního nebo nelineárního modelu GARCH s parametry φ .

Vektor parametrů kompletního modelu tedy je $\theta = (\eta', \varphi')'$.

Tyto parametry lze odhadnout metodou maximální věrohodnosti neboli z angličtiny „log likelihood“. Jestliže e_t má normované normální rozdělení, logaritmus věrohodnosti funkce pro časovou řadu o rozsahu T pozorování má tvar

$$L(\theta) = \sum_{t=1}^T l_t(\theta), \quad (3.37)$$

kde

$$L(\theta) = -\frac{1}{2} \ln 2\pi - \frac{1}{2} \ln h_t - \frac{\varepsilon_t^2}{2h_t}. \quad (3.38)$$

Maximálně věrohodný odhad $\hat{\theta}$ se získává maximalizací logaritmu funkce. Tento odhad řeší rovnici

$$\sum_{t=1}^T \frac{\partial l_t(\theta)}{\partial \theta} = 0. \quad (3.39)$$

Vztah $\frac{\partial l_t(\theta)}{\partial \theta}$ se označuje jako skórová funkce $s_t(\theta)$. Přičemž lze tuto funkci rozdělit na dvě složky, kdy jedna bude odpovídat úrovněmu modelu a druhá modelu volatility. Rozložená funkce je ve tvaru

$$s_t(\theta) = \left(\frac{\partial l_t(\theta)}{\partial \eta'}, \frac{\partial l_t(\theta)}{\partial \varphi'} \right), \text{ kde} \quad (3.40)$$

$$\frac{\partial l_t(\theta)}{\partial \eta'} = \frac{\varepsilon_t}{g_t} \frac{\partial G(X_t, \eta)}{\partial \eta} + \frac{1}{2h_t} \left(\frac{\varepsilon_t^2}{h_t} - 1 \right) \frac{\partial h_t}{\partial \eta}, \quad (3.41)$$

$$\frac{\partial l_t(\theta)}{\partial \varphi'} = \frac{1}{2h_t} \left(\frac{\varepsilon_t^2}{h_t} - 1 \right) \frac{\partial h_t}{\partial \varphi}. \quad (3.42)$$

Z důvodu, že podmínka $\sum_{t=1}^T \frac{\partial l_t(\theta)}{\partial \theta} = 0$ je nelineární v parametrech, používá se k získání maximálně věrohodného odhadu iterativní optimalizační procedura. Pokud je odhad parametru získaný v i -té iteraci označen $\hat{\theta}^{(i)}$, pak se $\hat{\theta}^{(i+1)}$ získá ze vztahu

$$\hat{\theta}^{(i+1)} = \hat{\theta}^{(i)} - \lambda \left(\sum_{t=1}^T \frac{\partial t_t(\hat{\theta}^{(i)})}{\partial \theta} \frac{\partial t_t(\hat{\theta}^{(i)})}{\partial \theta'} \right)^{-1} \sum_{t=1}^T s_t(\hat{\theta}^{(i)}). \quad (3.43)$$

Pokud je podmíněné rozdělení pravděpodobnosti určené správně, odhad parametrů je konzistentní a asymptoticky normální. Podmínka normality procesu $\{\varepsilon_t\}$ není v případě finančních časových řad splněna. V případě, že se nám nepodaří zachytit skutečnou špičatost rozdělení, opouští se předpoklad normality a přijímá se jiný předpoklad, např. že se jedná o Studentovo rozdělení. Obvykle se však postupuje tak, že se rozdělení nebere v úvahu, a automaticky se předpokládá normalita, tato metoda se pak označuje jako quasi metoda maximální věrohodnosti. Jsou-li modely úrovně a modely volatility správně určeny, takto získané odhady jsou stále konzistentní a asymptoticky normální, toto platí rovněž u modelu typu IGARCH. Touto problematikou se zabýval Weiss (1984), Bollerslev, Wooldridge (1992), Lee, Hansen (1994). Quasi metoda maximální věrohodnosti může být použita i modelu GARCH, kde jsou výsledky téměř stejné s výsledky metody maximální věrohodnosti, avšak v případě zešikmení jsou výsledky jiné než u metody maximální věrohodnosti, viz Arlt (1999) a Rublíková (2008).

3.7 Testování vhodnosti modelu

Testování vhodnosti modelu slouží k ověření splnění podmínek, které jsou kladeny na odhady parametrů lineárních a nelineárních modelů, a slouží také k otestování statistické významnosti parametrů. A jedná se rovněž o jeden z kroků modelování volatility. Je tedy nutné přistoupit k testování vhodnosti zvoleného modelu a posouzení vlastností náhodné složky modelu. Při popisování této části jsme vycházeli z publikací Arlt, Arltová (2003) a Rublíková (2008).

Prvním testovaným kritériem je test náhodné složky modelu, tedy nesystematické složky modelu. Rezidua modelu, u kterých předpokládáme nezávislost, nulovou střední hodnotu a jednotkový rozptyl můžeme vyjádřit vztahem

$$e_t = \varepsilon_t h_t^{-\frac{1}{2}}. \quad (3.44)$$

Pokud je model volatility určen správně, musí mít tyto vlastnosti i standardizovaná rezidua. Pro diagnostickou kontrolu je možné použít zejména testy kontroly normality, autokorelace a heteroskedasticity.

3.7.1 Test normality

V případě této práce bude použit Jarque–Bera test, který je založen na myšlence současného testování šikmosti a špičatosti. Vychází se přitom ze skutečnosti, že třetí normovaný moment (šikmost) normálního rozdělení je 0 a čtvrtý normovaný moment (špičatost) normálního rozdělení je 3.

Testové kritérium Jarque-Bera testu má následující podobu

$$JB = (SK^2 + KU^2), \quad (3.45)$$

kde SK je testové kritérium pro testování šikmosti rozdělení

$$SK = \left(\frac{T}{6} \right)^{\frac{1}{2}} \left(\frac{\hat{m}_3^2}{\hat{m}_2^3} \right)^{\frac{1}{2}}, \quad (3.46)$$

a KU je testové kritérium pro testování špičatosti rozdělení

$$KU = \left(\frac{T}{24} \right)^{\frac{1}{2}} \left(\frac{\hat{m}_4}{\hat{m}_2^2} - 3 \right), \quad (3.47)$$

přičemž

$$\hat{m}_j = \frac{1}{T} \sum_{t=1}^T \hat{a}_t^j, \quad j = 2, 3, 4. \quad (3.48)$$

V případě nulové hypotézy, která znamená normalitu nesystematické složky modelu, mají statistiky KU a SK asymptoticky normované normální rozdělení $N(0,1)$. Statistika Jarque-Bera má rozdělení $\chi^2(2)$. Kromě nenormality nesystematické složky může k zamítnutí nulové hypotézy vést skutečnost, že nesystematické složky nejsou homoskedastické.

3.7.2 Test autokorelace

Autokorelace bude hodnocena na základě výstupů z korelogramu. Autokorelaci nesystematické složky modelu lze posoudit pomocí výběrové autokorelační funkce

$$\hat{p}_k = \frac{\sum_t \hat{a}_t \hat{a}_{t-k}}{\sum_t \hat{a}_t^2}. \quad (3.49)$$

Není-li nesystematická složka autokorelována, měly by hodnoty této funkce ležet uvnitř intervalu $\pm 2\sqrt{T}$ (95% interval spolehlivosti).

Další možností, jak zjistit, zda nesystematická složka není autokorelována, je použití portmanteau testu, u kterého se testuje hypotéza $H_0 : \rho_1 = \rho_2 = \dots = \rho_K = 0$ proti hypotéze $H_1 : \text{non } H_0$, kde $\rho_k, k = 1, \dots, K$, jsou autokorelace nesystematické složky modelu pro zpoždění k .

Testové kritérium se pak konstruuje následovně

$$Q = T \sum_{k=1}^K \hat{\rho}_k^2, \quad (3.50)$$

kde pro vysoké T a K má statistika přibližně rozdělení χ^2 s $(K-p-q)$ stupni volnosti. Srovnáním testového kritéria s příslušnými kvantily rozdělení $\chi^2(K-p-q)$ lze testovat hypotézu o neautokorelovanosti hodnot nesystematické složky.

3.7.3 Test heteroskedasticity

Pro účely této práce byl zvolen ARCH LM test, který zkoumá, zda odhadnutý model vykazuje podmíněnou heteroskedasticitu typu ARCH či nikoliv. Autoři testu přitom využili práce Engle (1982) a Engle, Ng (1993).

Test se skládá ze 4 základních kroků:

1. Odhadnou se parametry modelu GARCH(p,q) a získají se standardizovaná rezidua a součet čtverců reziduí ESS_0 .
2. Vytvoří se regresní model s konstantou, ve kterém je na levé straně \hat{e}_t^2 a na pravé straně

$$\hat{e}_{t-1}^2, \dots, \hat{e}_{t-m}^2 \text{ a } \hat{x}_t = \hat{h}_t^{-1} \frac{\partial \hat{h}_t}{\partial \hat{\phi}},$$

na jehož základě se získá reziduální součet čtverců ESS_1 a index determinace R^2 .

3. Dále se pomocí testového kritéria LM ve tvaru TR^2 testuje hypotéza, že parametry u veličin $\hat{e}_{t-1}^2, \dots, \hat{e}_{t-m}^2$ jsou nulové a má za předpokladu nulové hypotézy asymptotické rozdělení $\chi^2(m)$.
4. Provádí se F-verze tohoto testového kritéria, jenž je vyjádřen vztahem

$$F_{LM} = \frac{\left(\frac{ESS_0 - ESS_1}{m} \right)}{\frac{ESS_1}{T - p - q - 1 - m}}, \quad (3.51)$$

kde její rozdělení lze za předpokladu platnosti nulové hypotézy aproximovat rozdělením $F(m, T - p - q - 1 - m)$.

3.7.4 Výběr modelu dle informačního kritéria

V některých případech se může stát, že dojde k identifikaci dvou či více přijatelných modelů. Potom vzniká otázka, který z nich zvolit.

Existují dva přístupy pro výběr modelu. První z nich je založen na dalším zkoumání a pozorování odhadnutých reziduí. Dává se přednost modelu s menší hodnotou odhadu reziduálního rozptylu a s menším počtem parametrů. Z tohoto principu vychází několik kritérií. Výběr nejvhodnějšího modelu je tedy založen na následujících kritériích:

- Akaikeho informační kritérium,
- Schwartzovo informační kritérium.

Akaikeho informační kritérium (AIC) je definováno následovně:

$$AIC = -2L/n + 2k/n, \quad (3.52)$$

kde k je počet odhadovaných parametrů, n počet pozorování a L hodnota funkce maximální věrohodnosti uvedená v rovnici 3.37.

Schwartzovo informační kritérium (SC) má tvar:

$$SC = -2L/n + k \log(n)/n. \quad (3.53)$$

Samotná informační kritéria slouží k určení míry informací, které postihují rovnováhu mezi mírou „významnosti a šetrnou specifikací“ modelu. Různá informační kritéria se liší v tom, jak vyhoví této rovnováze.

Jestliže při výběru vhodného typu modelu využíváme informační kritéria, zvolíme model s nejmenšími hodnotami těchto kritérií. Informační kritéria se velmi často využívají v analýze časových řad při určování příslušné délky zpoždění. Je nutné upozornit na skutečnost, že tato kritéria závisí na jednotné míře závislé proměnné. Není tedy možné užívat informační kritéria k výběru například mezi modely se závisle proměnnou y a například $\log y$.

Druhý způsob volby vhodného modelu spočívá v porovnání přesnosti předpovědí, které lze získat z výpočtů jednotlivých modelů. Časová řada se rozdělí na dvě části. Modely jsou odhadnuty na základě první části, druhá část je pak použita pro měření přesnosti předpovědí „ex post“.

3.8 Předpovědi na další období

Ekonomická praxe nevystačí s pouhým historickým či aktuálním odhadem volatility, ale žádá si předpověď volatility do budoucna. Proto se dá říci, že konstrukce lineárních a nelineárních modelů volatility slouží právě pro tvorbu předpovědí volatility, viz Arlt, Arltová (2003). Pod pojmem předpověď si nejčastěji vybavíme odhad budoucí hodnoty na základě znalosti minulých a přítomných hodnot. Toto pojetí vychází z endogenních hodnot a je typické pro předpovědi v časových řadách bez využití informace o vlivu exogenních faktorů, které mohou zvýšit účinnost předpovědi.

V případě modelů lineární a nelineární regrese se předpověď chápe odhad hodnoty vysvětlované proměnné pro dané hodnoty vysvětlujících proměnných.

Rozlišuje se předpověď *ex ante* a *ex post*. Predikce *ex ante*, kdy regresory nejsou známy a musíme je najít pomocí předpovědí v dalších modelech, ve kterých figurují jako vysvětlované. U metody *ex post* jsou tyto regresory známy, jelikož byly přímo vypočítány nebo je jejich hodnota zřejmá.

Jiné dělení předpovědí je na předpověď bodovou a intervalovou, kdy bodová předpověď je bodovým odhadem neznámé hodnoty vysvětlované proměnné a intervalová předpověď je intervalovým odhadem neznámé hodnoty vysvětlované proměnné.

Problematiku konstrukce bodových a intervalových předpovědí na základě lineárních úrovnových modelů při podmíněné heteroskedasticitě rozpracovali Baillie a Bollerslev (1992).

Bodové předpovědi konstruované na základě autoregresivních modelů jsou v případě podmíněné homoskedasticity a podmíněné heteroskedasticity identické. Podmíněnou střední čtvercovou chybu je však možné použít ke konstrukci intervalových předpovědí, které jsou při podmíněné heteroskedasticitě odlišné než při podmíněné homoskedasticitě, viz Arlt (2003). Jejich konstrukce je však velmi obtížná, protože podmíněné pravděpodobnostní rozdělení předpovědních chyb e_t není normální. V této situaci Baillie a Bollerslev (1992) navrhli postup, který je založen na Edgeworthově rozvoji a použití Cornishovy-Fisherovy aproximace kvantilů podmíněného rozdělení předpovědních chyb e_t .

Výpočet předpovědi podmíněného rozptylu je možný na základě lineárních a nelineárních modelů volatility, a proto budou tyto dva typy výpočtu popsány níže.

První výpočet je tedy předpověď podmíněného rozptylu na základě lineárních modelů volatility, u kterého se pracuje s modelem GARCH(p,q) ve tvaru

$$h_t = \omega + \alpha_1 \varepsilon_{t-1}^2 + \dots + \alpha_q \varepsilon_{t-q}^2 + \beta_1 h_{t-1} + \dots + \beta_p h_{t-p}, \quad (3.54)$$

pro $t = T + h$ potom dostaneme

$$h_{T+h} = \omega + \alpha_1 \varepsilon_{T+h-1}^2 + \dots + \alpha_q \varepsilon_{T+h-q}^2 + \beta_1 h_{T+h-1} + \dots + \beta_p h_{T+h-p}. \quad (3.55)$$

Předpověď s minimální střední čtvercovou chybou hodnoty h_{T+s} , lze zapsat ve tvaru

$$h_T(h) = \omega + \alpha_1 \varepsilon_T^2 (h-1) + \dots + \alpha_q \varepsilon_T^2 (h-q) + \beta_1 h_T (h-1) + \dots + \beta_p h_T (h-p). \quad (3.56)$$

V případě, že by se předpokládala předpověď na základě modelu GARCH(1,1), pak by podmíněný rozptyl byl ve tvaru dle vzorce (3.11) a po aplikaci $t = T + h$ by měl tvar

$$h_{T+h} = \omega + \alpha_1 \varepsilon_{T+h-1}^2 + \beta_1 h_{T+h-1}. \quad (3.57)$$

Předpověď podmíněného rozptylu pak lze vyjádřit jako

$$\begin{aligned} h_T(h) &= \omega \sum_{j=0}^{h-1} (\alpha_1 + \beta_1)^j + (\alpha_1 + \beta_1)^{h-1} \alpha_1 \varepsilon_T^2 + (\alpha_1 + \beta_1)^{h-1} \beta_1 h_T = \\ &= \omega \sum_{j=0}^{h-2} (\alpha_1 + \beta_1)^j + (\alpha_1 + \beta_1)^{h-1} h_{T+1} \end{aligned} \quad (3.58)$$

Pokud by byl model GARCH(1,1) kovariančně stacionární, pak platí, že $\alpha_1 + \beta_1 < 1$ a $\sigma_\varepsilon^2 = \omega(1 - \alpha_1 + \beta_1)^{-1}$, v tomto případě by model vypadal následovně

$$h_T(h) = \sigma_\varepsilon^2 + (\alpha_1 + \beta_1)^{h-1} (h_{T+1} - \sigma_\varepsilon^2), \quad (3.59)$$

z čehož vyplývá, že s rostoucím horizontem prognózy h předpověď podmíněného rozptylu konverguje k nepodmíněnému rozptylu procesu $\{\varepsilon_t\}$ a význam současné informace se ztrácí, viz Rublíková (2008).

Druhý výpočet předpovědi podmíněného rozptylu je na základě nelineárních modelů volatility, kdy pro většinu nelineárních modelů zde uvedených je jednodušší konstruovat předpovědi podmíněného rozptylu oproti úrovnovým nelineárním modelům. Toto tvrzení vychází z Frances a van Dijk (2000).

4 Empirická analýza volatility vybraných akciových indexů

Vzhledem k cílům stanovených v úvodní části práce je nutné využít teoretické poznatky z druhé a třetí kapitoly za účelem provedení empirické analýzy volatility zvolených akciových indexů. Nejdříve je však nutné charakterizovat zvolené akciové indexy, popsat jejich bázi a charakterizovat data o jejich vývoji.

Neméně důležitá je také charakteristika akciových trhů příslušných k zvoleným indexům, viz kapitola 4.1. Kapitola 4.2 je věnována volbě dat, tedy popisu jednotlivých období a popisné statistice jednotlivých zkoumaných časových řad. Výsledky zkoumání budou prezentovány v grafické a numerické podobě a pomohou k identifikaci charakteristických vlastností pro jednotlivé časové řady a potažmo i pro konkrétní zkoumané období.

V dalších pokapitolách se u časových řad provádí testy stacionarity, heteroskedasticity a autokorelace, odhadují se nejlepší lineární a nelineární modely, u kterých se dále provádí testy vhodnosti modelu. Vycházíme přitom z části teoreticko-metodologické, zejména z kapitoly 3.2, ve které je popsána výstavba modelu volatility. Jelikož se jedná o aplikační část práce, tak v podkapitolách bude značné množství grafů, tabulek a obrázků, jenž jsou z velké části výstupy programu SPSS a EViews.

4.1 Základní charakteristika a vývoj akciových trhů v zemích střední Evropy

Vzhledem k tomu, že práce je zaměřena na modelování volatility akciových indexů zemí střední Evropy, je nutné charakterizovat akciový trh zemí střední Evropy. Akciové trhy hrají v dnešním světě velkou roli, jelikož mají významný vliv na hrubý domácí produkt (HDP) a potažmo i na celkový ekonomický vývoj jednotlivých zemí. Tato kapitola bude věnována charakteristice vybraných burz zemí střední Evropy s důrazem na historii, typy obchodování apod. V další části budou popsány burzovní indexy vybraných zemí včetně postupu jejich výpočtu a skladby jejich báze.

4.1.1 Burzy

Pod pojmem burza cenných papírů dále „burza“ se chápá určitá instituce, která organizuje a koordinuje trh s investičními nástroji. Na burze se setkává nabídka po investičních nástrojích s poptávkou po investičních nástrojích a probíhají tam tedy operace nákupu a prodeje. Na straně nabídky se vyskytují emitenti, kteří na burze emitují cenné papíry (CP) za účelem získání finančních prostředků, a na straně poptávky jsou investoři, kteří mají nadbytek

finančních prostředků a chtějí je zhodnotit. Na burze se obchoduje zejména s akcemi a dluhovými cennými papíry, které představují standardizované transakce, viz Polách (2006).

Jelikož je tato práce zaměřena na střední Evropu, pak je na místě vypsát nejznámější středoevropské burzy, mezi které patří:

- Budapešť - Budapest Stock Exchange (index BUX),
- Varšava – Giełda papierów wartościowych w Warszawie (index WIG),
- Bratislava – Burza cenných papierov Bratislava (index SAX),
- Praha – Burza cenných papírů Praha (index PX).

A za hlavní Evropská centra se přitom považuje:

- Londýn - International Stock Exchange London – akcie (index FT-SE 100),
- Frankfurt – Frankfurter Wertpapierbörse - dluhopisy (index DAX).

V dalších podkapitolách budou popsány vybrané středoevropské burzy a jejich indexy, a bude se tedy konkrétně jednat o burzy Maďarska, Polska, Slovenska a České republiky.

a) *Maďarsko*

Organizátorem trhu s CP je v Maďarsku Burza cenných papírů v Budapešti (BSE), jejímž cílem je zajistit průhledný a likvidní trh pro své kótované cenné papíry vydané buď přímo v Maďarsku, nebo v zahraničí. Burza cenných papírů v Budapešti jakožto klíčová instituce domácího finančního trhu, poskytuje různorodým ekonomickým subjektům možnost zvýšit kapitál na otevřených trzích a nabízí investorům efektivní investiční příležitosti.

Burza cenných papírů v Budapešti byla znovuotevřena 41 členy po převratu, tedy 21. 6. 1990. A zajímavostí je, že o roku 2005 se na burze obchoduje i s komoditami. V roce 2004 byla přijata do Federace evropských burz (FESE).

Struktura trhu Burzy cenných papírů v Budapešti je rozdělena na 4 sekce:

- a) sekce majetkových cenných papírů, kde patří akcie, fondy, certifikáty,
- b) sekce dluhových cenných papírů, zde patří pokladniční poukázky a státní dluhopisy, stejně tak korporátní dluhopisy a hypoteční zástavní listy,
- c) sekce derivátů, tedy futures a opce na akcie, indexy, měny a úrokové míry,
- d) sekce komodit.

Tyto čtyři sekce se považuje za hlavní trh, kromě něj pak na BSE existuje neregulovaný trh, kde jsou obchodovány CP, které nejsou oficiálně listovány na BSE.

Dalším dělením je pak dělení do kategorie A a B. CP kategorie A musí splňovat určité požadavky z hlediska velikosti, likvidity a transparentnosti. V kategorii B jsou zařazeny společnosti, které splňují základní požadavky pro uvedení na burzu a jsou zde většinou menší a střední společnosti.

b) Polsko

Hlavní polskou burzou je Giełda Papierów Wartościowych w Warszawie (GPW). Tradice kapitálové trhu v Polsku sahají až do roku 1817, kdy se svolalo první Kupeckou Burzu ve Varšavě. Svoji současnou činnost GPW začala dne 16. dubna 1991, kdy hned od začátku organizovala obrat cenných papírů v elektronické podobě. GPW je akciovou společností založenou ministerstvem financí.

Na GPW se obchoduje s cennými papíry jako akcie, obligace, investiční certifikáty, termínované kontakty, opce atd.

GPW se dělí na dva trhy:

- a) Hlavní trh GPW, který funguje od založení burzy. Jedná se o trh regulovaný, který podléhá Komisji Nadzoru Finansowego a také Evropské Komisi.
- b) Dalším trhem je New Connect, což je organizovaný trh vedený GPW, který působí jako alternativní systém obratu. Vznikl z myšlenky o nových rozvíjejících se firmách a působí zejména ve sféře nových technologií. New Connect vznikl 30. srpna 2007.

GPW se odlišuje od jiných burz zejména vlastnictvím a historickým vývojem, neboť hlavním akcionářem je stát v podobě Skarbu państwa, což je státní finanční úřad. Vznik polského kapitálového trhu se liší od vzniku českého kapitálového trhu, který vznikl kupónovou privatizací. Naopak v Polsku byl kapitálový trh využíván postupně skrze jednotlivé emise akcií, a proto nedošlo k masivnímu úbytku CP kótovaných na GPW.

Z hlediska mezinárodního se GPW stává hlavním centrem obchodu s akciemi v regionu, což se projevuje poměrně vysokým počtem zahraničních společností kótovaných této burze. Roste počet členů burzy a z hlediska hodnoty Initial Public Offering (IPO) GPW vede před ostatními burzami regionu.

c) Slovensko

Na Slovensku je organizátorem trhu s cennými papíry Burza cenných papierov v Bratislave a.s., (BCPB) která vznikla 15. března 1991 jako akciová společnost na základě rozhodnutí ministerstva financí. BCPB je na Slovensku jediným organizátorem regulovaného trhu s cennými papíry. Teprve 6. dubna 1993 se na této burze začalo obchodovat, i když burza vznikla již dříve. Od roku 2001 vykonává svou činnost na základě povolení Úřadu pro finanční trh Slovenské republiky. V současnosti BCPB provádí rovněž dohled a organizování mnohostranného obchodního systému, a to na základě rozhodnutí Národní banky Slovenska (NBS). Členem BCPB pak může být právnická osoba obchodující s CP, která má povolení od NBS nebo právnická osoba, která musí být v pracovněprávním vztahu s fyzickou osobou s makléřskou licenci.

BCPB funguje na členském principu, což tedy znamená, že uzavírat burzovní obchody můžou jen členové burzy, případně Národní banka Slovenska.

V roce 2004 se BCPB stala členem FESE stejně jako ostatní zmiňované burzy.

Na burze jsou prováděny následující typy obchodů:

- a) Kurzotvorné obchody, které se uzavírají v Elektronickém burzovním obchodním systému (EBOS), kde dochází k párování objednávky na nákup a prodej. Tyto obchody jsou srovnatelné s českou typizací burzovních obchodů, tedy patří zde aukční obchodování neboli obchodování s fixní cenou, kontinuální obchodování, obchodování s tvůrci trhu a blokové obchody.
- b) Přímé obchody, kde je cena a objem předem určen na základě dohody kupujícího a prodávajícího, přičemž platí, že se obě strany znají.
- c) Repo obchody, které představují prodej CP za hotovost a vzájemná dohoda o jejich zpětném odkupu k určitému datu v budoucnosti za předem stanovenou cenu.
- d) Nabídky na převzetí, kdy právnické nebo fyzické osoby mají možnost případně povinnost uskutečnit nabídku nebo povinnou nabídku na převzetí společnosti. Povinná nabídka na převzetí se vztahuje na výše jmenované osoby, jejichž podíl hlasovacích práv spojených s akciemi jednoho emitenta dosáhne nebo přesáhne 33%, 50% a 66%.

Burzovní trh se dělí na 3 části:

- a) Kótovaný paralelní trh, jenž má několik specifíků, které se rozlišují dle přijímaných instrumentů. Na kótovaný paralelní trh se přijímají akcie, dluhopisy a podílové listy, které splňují určité podmínky stanovené zákonem. Mezi tyto podmínky patří požadavek na hospodářský výsledek emitenta, velikost tržní kapitalizace, objem vydané emise, délka podnikatelské činnosti emitenta atd.
- b) Pro kótovaný hlavní trh platí stejné podmínky jako pro trh paralelní, pouze některé podmínky u akcií a dluhopisů jsou odlišné a nastavené přísněji. Pro tento trh je i více podmínek, např. rozšíření o podmínku na počet majitelů emise apod.
- c) Regulovaný volný trh je trh, kde se přijímají CP, které jsou vydávány v souladu s právními předpisy a zákonem o burze. Na tento trh se nepřijímají CP emitenta, který je v likvidaci nebo na jeho majetek byl vyhlášen konkurz.

d) Česká republika

V České republice je největším organizátorem trhu s cennými papíry Burza cenných papírů Praha (BCPP) a vedle ní existuje RM-Systém, což je burza pro malé a střední investory. Jelikož se tato práce týká zejména akciových indexů, tak o komoditních burzách nebude zmínka.

BCPP je ze zákona akciovou společností, která vznikla 24. 11. 1992. Je založena na členském principu, což znamená, že přístup do burzovního systému a právo obchodovat mají pouze licencovaní obchodníci s cennými papíry, kteří jsou zároveň členy burzy. Pražská burza si získala pozici respektovaného a stabilního trhu. Je členem Federace evropských burz (FESE). Trvalému zájmu se pražská burza těší jak mezi domácími, tak i mezi zahraničními investory.

Na burze jsou prováděny následující typy obchodů:

- a) Automatické obchody v aukčním režimu, které jsou založeny na shromáždění objednávek k nákupu a prodej investičních instrumentů k jednomu časovému okamžiku. Výsledkem je pak stanovení aukční ceny. Na obchodování v tomto režimu navazuje kontinuální režim. Tento režim je kurzotvorný pro instrumenty zařazené do 2. obchodní skupiny.
- b) Automatické obchody v kontinuálním režimu umožňuje uzavírání obchodů na základě průběžně zadávaných objednávek k nákupu a prodeji investičních instrumentů.

Na přijaté objednávky se uplatňuje princip cenové a následně časové priority. Tento režim je kurzotvorný pro instrumenty zařazené do 1. obchodní skupiny.

- c) Systém pro podporu trhu akcií a dluhopisů (SPAD) – zde mohou být realizovány pouze obchody s vybranými emisemi akcií. Nákupní a prodejní ceny se stanoví průběžně tvůrci trhu, kteří mají za úkol zajišťovat dostatečnou likviditu. Tento režim je kurzotvorný pro instrumenty zařazené do 3. obchodní skupiny.
- d) Blokové obchody jsou obchody uzavřené mimo obchodní systém burzy, kde alespoň na jedné straně vystupuje člen burzy. Cena obchodu pak není nijak spojena s kurzem daného instrumentu, a proto není ani kurzotvorným segmentem.
- e) Obchody s účastí specialisty, tedy obchody určené pro obchodování produktů, u kterých není možné zajistit dostatečný počet tvůrců trhu pro obchodování ve SPADu. Tento způsob je určen pro obchodování s investičními certifikáty.
- f) Futures obchody probíhají na stejném principu jako SPAD obchody, tedy i v tomto případě je likvidita zajišťována tvůrci trhu.

Burzovní trhy se dělí na 3 kategorie:

- a) Hlavní trh, který je určen pro objemově velké emise společností, které jsou ochotny průběžně poskytovat informace o svém hospodaření. Umístění emise na tyto trhy jsou pro emitenta prestižní záležitostí.
- b) Volný trh, na kterém Burza na emitenty neklade vyšší nároky jako v případě hlavního trhu, tedy nároky nepřesahují obecně platné zákony týkající se kapitálového trhu.
- c) Trh MTF, což je mnohostranný obchodní systém zavedený s účinností od 1. 12. 2008. Jedná se o neregulovaný trh, tzn., že veškeré podmínky přijetí, přístupu a obchodování stanovuje burza.

Roli indikátoru trhu s cennými papíry představují burzovní indexy, v případě českého kapitálového trhu je hlavním indikátorem index PX a index RM. V části zaměřené na burzovní indexy se budeme zabývat pouze indexem PX, který je hlavním indexem BCPP.

4.1.2 Burzovní indexy

Jelikož je práce zaměřena na modelování volatility akciových indexů, tak je nutné pochopit co je akciový index a jak se počítá. Burzovní index je ukazatelem vývoje daného trhu jako celku, slouží ke sledování vývoje trhu v čase a jeho vývojovým tendencím. Protože burzovní index odráží jak současný stav vývoje trhu, tak i dlouhodobý vývoj trhu s jeho tendencemi, lze jej

také použit jako určité měřítko úspěšnosti dlouhodobého vývoje investorova portfolia z hlediska výnosů. Každý burzovní či mimoburzovní trh má svůj vlastní index, za jednotlivé druhy cenných papírů obchodovaných na trhu. Za nejdůležitější jsou považovány indexy akciové.

V následujících podkapitolách budou rozebrány akciové indexy s návazností na kapitulu 4.1.1. K jednotlivým subjektivně vybraným zemím, popsáných v kapitole 4.1.1, budou tedy přiřazeny jejich hlavní akciové indexy. S těmito indexy a jejich hodnotami pak budeme pracovat v dalších částech této práce.

a) Index BUX

Index BUX je oficiální index blue chip akcií kótovaných na BSE. Je kalkulován v reálném čase burzou každých 5 vteřin, a to na základě aktuálních tržních cen koše akcií. BUX náleží ke skupině indexů založených na váženém průměru cen akcií. Index ukazuje průměrnou změnu cen akcií s největší tržní hodnotou a obrat v akciové části. Z tohoto důvodu je nejdůležitějším indexem označujícím burzovní trendy.

BSE byla jednou z prvních burz na světě, kde začali používat koeficienty volno-oběhové kapitalizace namísto koeficientů tradiční tržní kapitalizace, stalo se tak v říjnu 1999. Váhami byly do roku 1999 velikosti emisí akcií zahrnutých do indexu. Od tohoto roku se tržní cena příslušné akcie váží počtem akcií ve veřejném vlastnictví. To znamená, že v úvahu nejsou brány ty akcie, které drží samotná společnost, její vrcholový management, zaměstnanci atd.

Index BUX je rovněž obchodní index a jeho futures a deriváty lze nalézt v obchodní sekci. Na burze se obchoduje od 9:00 do 16:30. Index BUX bere v úvahu i výplaty dividend a na jeho bázi se podílí několik proměnlivých akciových titulů, a to do maximálního množství 25. Revize se pak provádí dvakrát do roka v březnu a září. Index BUX je vyjádřen vztahem

$$BUX_t = K \frac{\sum_{i=1}^n p_{it} q_{iT} D_i}{\sum_{i=1}^n p_{i0} q_{iT}} 1000, \quad (4.1)$$

kde n je počet akciových titulů obsažených v indexu, i je konkrétní akciový titul obsažen v indexu, K je koeficient úprav k zajištění kontinuity indexu, D_i je faktor k úpravě změny v tržní hodnotě akcie za pomoci odříznutí dividendového kupónu. q_{iT} je pak množství akcií zařazených do indexního koše z konkrétní akciové série. p_{i0} je průměrná cena k druhému

lednu 1991 a p_{it} je otvírací cena konkrétního akciového titulu jako by se vyvinula, poslední obchodovaná cena konkrétního akciového titulu ve volném období obchodování, a poslední závírací cena pro uzavření hodnoty BUX.

Tab. 4.1 *Báze indexu BUX k 27. 1. 2010*

Název	ISIN	Počet CP	Tržní kapitalizace	Upravená tržní kapitalizace	Váha v koši (%)
ANY	HU0000093257	9 557 190	8 639 699 760	8 295 640 920.00	0.33
ECONET	HU0000058987	49 500 000	6 187 500 000	8 068 500 000.00	0.24
EGIS	HU0000053947	3 788 448	69 328 598 400	9 088 486 752.00	2.65
EMASZ	HU0000074539	308 260	6 843 372 000	4 019 093 880.00	0.26
FHB	HU0000078175	43 155 466	59 770 320 410	32 677 318 855.20	2.28
FOTEX	HU0000096409	32 651 366	12 538 124 544	6 236 410 906.00	0.48
MOL	HU0000068952	40 610 674	735 053 199 400	61 403 339 088.00	28.10
MTELEKOM	HU0000073507	509 192 221	363 563 245 794	660 422 310 637.00	13.90
OTP	HU0000061726	136 513 604	779 492 678 840	14 292 974 338.80	29.79
RICHTER	HU0000067624	13 876 621	563 390 812 600	24 839 151 590.00	21.53
SYNERGON	HU0000069950	8 522 932	6 477 428 320	5 292 740 772.00	0.25
TVK	HU0000073119	1 587 072	4 959 600 000	2 139 373 056.00	0.19

Zdroj: www.bse.hu

Z Tab. 4.1 je tedy patrné, že k 27. 1. 2010 mělo na index BUX vliv 12 společností kótovaných na BSE. Procentní rozdělení podílů je v případě indexu BUX velmi podobné českému indexu PX. I zde má tržní kapitalizace 4 akciových společností silný vliv na index BUX.

b) Index WIG

Index WIG neboli Warszawski Index Giełdowy, je burzovní index příjmového typu, který je nejstarším pozorovaným indexem na GPW. Index se počítá od 16. dubna 1991 a do báze indexu jsou zařazeny akcie společností na hlavním trhu. Jelikož se jedná o index příjmového typu, tak se berou v úvahu ceny akcií v něm obsaženém, ale na rozdíl od indexu PX, ovlivňují tento index i dividendové výnosy, které se do výpočtu rovněž zahrnují. Vliv jedné společnosti na index WIG nemůže překročit 10% a účast jednoho sektoru nemůže v indexu překročit 30% podíl. Změny ve složení indexu WIG jsou prováděny 4krát do roka, a to po posledních obchodních dnech února, května, srpna a listopadu.

Index je kalkulován v době obchodování od 8:30 do 16:10 v 60 vteřinových intervalech.

Výpočet indexu WIG se řídí dle vztahu

$$WIG(t) = \frac{M(t)}{M(0)K(t)} 1000, \quad (4.2)$$

kde $M(0) = 57140000 \text{ PLN}$, což představuje tržní kapitalizaci ve výchozím dni 16. 4. 1991.

$M(t)$ je tržní kapitalizace báze indexu ve dni obchodování v čase t neboli $M(t) = \sum P_i \times S_i$, kde P_i je aktuální kurz ve dni obchodování a S_i je počet akcií. $K(t)$ je pak váhový faktor indexu ve dni obchodování t , přičemž platí že,

$$K(t) = \frac{M(t) + Q(t)}{M(t)} K(t'), \quad (4.3)$$

kde $K(t')$ je hodnota dosud známého váhového faktoru, $K(t)$ je nová hodnota váhového faktoru, $Q(t)$ je hodnota tržní kapitalizace nového člena indexu a $M(t)$ je kapitalizace portfolia indexu před změnou.

K 22. lednu 2010 se báze indexu WIG skládá z 319 akciových společností. Z důvodu velkého rozsahu je celá báze k nalezení v příloze č. 1. Báze indexu sestavena z 319 společností je diverzifikací, která zaručuje menší výkyvy v indexu při špatném hospodaření jednotlivých společností, toto je zaručeno velkým množstvím společností působících na GPW.

c) Index SAX

Jedná se o slovenský akciový index, který je oficiálním indexem BCPB. Patří ke kapitálově váženým indexům a porovnává tržní kapitalizaci vybraného souboru akcií s tržní kapitalizací toho stejného souboru akcií k určitému referenčnímu dni. Jedná se tedy o index, který odráží celkovou změnu majetku spojenou s investováním do akcií zařazených do indexu, což znamená, že kromě změn cen index zahrnuje i dividendové příjmy a příjmy souvisejícími se změnami velikosti akciového kapitálu. Lze tedy říci, že je tento index velmi podobný polskému indexu WIG. Počáteční hodnota indexu k referenčnímu dni je 100 bodů. Index SAX odráží vývoj na BCPB, přičemž do 30. 6. 2001 byl postaven na průměrných cenách uvedených v kurzovních lístcích. Změna nastala od 1. 7. 2001, kdy se oficiální denní hodnota vypočítává a zveřejňuje na základě závěrečných kurzů bazických titulů.

Na BCPB se může obchodovat během pracovních dnů, s výjimkou dnů, které BCPB vyhlásí za burzovní prázdniny. Během státních svátků a víkendů se na burze neobchoduje. Na burze se obchoduje od 10:30 do 14:00.

Výpočet indexu SAX se řídí dle vztahu

$$SAX_{act} = \frac{\sum_i P_i^{act} G_i}{\sum_i P_i^I G_i F_i} 100, \quad (4.4)$$

kde F_i je opravný faktor pro i -tou akcii, P_i^{act} je závěrečná cena i -té akcie k danému dni, G_i je počet akcií i -té společnosti k danému dni a P_i^I představuje závěrečnou cenu i -té akcie k referenčnímu dni, tedy k 14. 9. 1993.

Tab. 4.2 *Váhy bazických indexů k 31. 12. 2009*

Název	ISIN	Váha (%)
Biotika, a.s.	CS0009013453, SK1120004009	4,90
OTP Banka Slovensko, a.s.	SK1110001452, SK1110004613	29,77
Slovenské energetické strojárne, a.s.	SK1120008034	16,54
Slovnaft, a.s.	CS0009004452, SK1120001369, SK1120005949	24,92
Všeobecná úverová banka, a.s.	SK1110001437	23,87

Zdroj: www.bcpb.sk

V Tab. 4.2 jsou zahrnuty akciové tituly, které ovlivňují bázi indexu SAX, a to ke dni 31. 12. 2009. Je tedy patrné, že index ovlivňuje pouze 5 největších společností, které emitovaly své akcie na BCPB.

d) Index PX

Index PX je oficiálním indexem BCPP. První výpočet indexu PX se uskutečnil 20. 3. 2006, kdy se stal nástupcem indexů PX 50 a PX-D. Index PX převzal historické hodnoty nejstaršího indexu burzy PX 50 a spojitě na ně navázal. Do báze indexu PX bylo v den jeho uvedení na burzu zařazeno celkem 9 nejlikvidnějších emisí burzovního trhu. Od prosince 2001 je počet bazických emisí variabilní. Index PX je cenovým indexem, dividendové výnosy se ve výpočtu nezohledňují. Index je kalkulován v době obchodování v rámci cenotvorných segmentů, a to od 9:11 do 16:07 hodin v 15 vteřinových intervalech.

Výpočet indexu PX se řídí dle vztahu

$$PX(t) = K(t) \frac{M(t)}{M(0)} 1000, \quad (4.5)$$

kde $M(0) = 379786853620$ Kč, což představuje tržní kapitalizaci ve výchozím dni 5. 4. 1994.

$K(t)$ je faktor zřetězení v čase t , čili dochází k zohledňování změn provedených v bázi

indexu, přičemž pro $K(0)$ ke dni 5. 4. 1994 platí, že $K(0) = 1$. $M(t)$ je tržní kapitalizace báze v čase t definována vzorcem

$$M(t) = \sum_{i=1}^{N(t)} q_i(t) p_i(t), \quad (4.6)$$

kde $q_i(t)$ představuje počet cenných papírů i -té bazické emise uplatněný ve výpočtu indexu v čase t , $p_i(t)$ označuje kurz i -té bazické emise v čase t a $N(t)$ představuje počet bazických emisí v čase t .

Tab. 4.3 *Báze indexu PX k 21. 1. 2010*

Název	ISIN	Redukovaný počet CP	Redukovaná tržní kapitalizace [mil. Kč]	Váha [%]
ČEZ	CZ0005112300	235 003 770	214 558,4	24,75
ERSTE GROUP BANK	AT0000652011	285 981 510	211 998,1	24,46
KOMERČNÍ BANKA	CZ0008019106	38 009 852	147 098,1	16,97
TELEFÓNICA O2 C.R.	CZ0009093209	322 089 890	143 007,9	16,50
NWR	NL0006282204	264 330 100	51 940,9	5,99
CETV	BMG200452024	50 524 273	28 616,9	3,30
UNIPETROL	CZ0009091500	181 334 764	26 202,9	3,02
PHILIP MORRIS ČR	CS0008418869	1 913 698	18 869,1	2,18
VIG	AT0000908504	16 201 564	15 619,9	1,80
PEGAS NONWOVENS	LU0275164910	9 229 400	4 042,5	0,47
ECM	LU0259919230	6 868 092	2 129,1	0,25
ORCO	LU0122624777	10 943 866	1 822,3	0,21
AAA	NL0006033375	67 757 875	978,4	0,11

Zdroj: www.bcphp.cz

Z Tab. 4.3 lze vyčíst všechny akciové tituly, které se podílejí na velikost indexu PX. Jejich podíl na indexu není nijak omezen. Zajímavostí je, že první 4 tituly ze všech 13 ovlivňuje index PX zhruba z 80%, což znamená, že vývoj ostatní nijak razantně nezasáhne do vývoje tohoto indexu, avšak na druhé straně to však může způsobit značné výkyvy v hodnotě indexu.

4.2 Volba dat a jejich základní statistická analýza

Kapitola 4.1 byla věnována charakteristice vybraných burz a jejich hlavním akciovým indexům. Volba dat je velmi důležitým krokem, jelikož špatně zvolená data znamenají rovněž špatný výsledek a závěrečnou interpretaci. Proto je tedy nutné vybrat takový vzorek dat, který zajistí reprezentativnost a srovnatelnost.

V předložené diplomové práci budeme pracovat s finančními časovými řadami, u kterých však existuje několik problémů. Prvním z nich je existence tzv. neekvidistantnosti způsobené tím, že se na akciových trzích neobchoduje každý den, viz kapitola 2.3. Druhým možným problémem spojeným s volbou dat je délka testovaných časových řad, kdy je třeba přihlížet zejména k historickému vývoji daného kapitálového trhu. Krátké finanční časové řady nemusí být dostačující pro odhalení všech zákonitostí a na druhé straně dlouhé finanční časové řady mohou podávat zavádějící výsledky, jelikož v dlouhém období dochází většinou ke změně procesu, který je ovlivňuje. Cílem zpracování finančních časových řad je tedy analýza zákonitostí jejich průběhu, zjištění odchylek od nalezené pravidelnosti a předpovídání jejich průběhu včetně řízení příslušných procesů, kterými jsou ovlivňovány.

V práci byly subjektivně vybrány čtyři středoevropské státy, Maďarsko, Polsko, Slovensko a Česká republika, viz kapitola 4.1.1, ze kterých byly vybrány čtyři hlavní akciové indexy, reprezentující akciový trh zvolených zemí. Mezi tyto index patří index BUX, WIG, SAX a PX, viz kapitola 4.1.2. K ostatním akciovým indexům se nepřihlíželo.

Vzhledem k cílům diplomové práce byla zvolena dvě testovací období:

- a) období je od 1. 5. 2004 do 31. 12. 2007,
- b) období je od 1. 5. 2006 do 31. 12. 2009.

Dělení bylo zvoleno zejména z důvodu zjištění stability vývoje volatility, kdy je první testovací období charakteristické svým stabilním vývojem volatility. Naopak období druhé v sobě zahrnuje šok způsobený světovou finanční krizí a předpokládáme, že vývoj volatility bude tedy odlišný od prvního období. Výchozí datum 1. 5. 2004 bylo zvoleno z důvodu vstupu všech čtyř zemí do Evropské unie. Pracujeme zde s uzavíracími kursy každého obchodního dne, což při denní frekvenci dat znamená, že bude k dispozici celkem 956 pozorování pro první období a 960 pozorování pro druhé období.

Vzhledem k tomu, že cílem této diplomové práce je modelování volatility vybraných akciových indexů BUX, WIG, SAX a PX je tedy nutné vytvořit čtyři časové řady pro první

období a čtyři časové řady pro druhé období. Dále budeme analyzovat denní výnosy těchto indexů za účelem splnění hlavního cíle práce.

Jak již bylo výše zmíněno, tak při výstavbě modelu hrají velkou roli data, se kterými se pracuje. Jelikož cena aktiva nemůže být menší než nula, pak je minimální dosažitelný přírůstek aktiva neboli minimální dosažitelný jednoduchý výnos aktiva

$$R_t = \frac{P_t - P_{t-1}}{P_{t-1}} = -1. \quad (4.7)$$

Protože náhodná veličina mající normální rozdělení může nabývat jakéhokoliv reálného čísla, není jeho dolní mez zaručena. To tedy znamená, že není zaručena ani dolní mez jednoduchého čistého výnosu.

V případě, kdyby jednoduché výnosy aktiva byly definovány jako

$$R_{t+1} = \frac{P_t}{P_{t-1}}, \quad (4.8)$$

tedy jako koeficienty růstu ceny aktiva, měly by mít rozdělení nezáporné náhodné veličiny. Pro vztah 4.8 se tedy nabízí využití logaritmicko-normálního rozdělení, kdy logaritmus náhodné veličiny s takovýmto rozdělením má rozdělení normální. Pokud má jednoduchý výnos R_{t+1} logaritmicko-normální rozdělení, potom jeho logaritmus

$$r_t = \ln(R_{t+1}) = \ln P_t - \ln P_{t-1} = p_t - p_{t-1} \quad (4.9)$$

má normální rozdělení.

Výnos aktiva za určité období k od času $t-k$ do času t lze pak vyjádřit jako součin k koeficientů růstu za jednotlivá období, tj. jako součin k jednoduchých výnosů aktiva

$$R_t(k) + 1 = (R_t + 1)(R_{t-1} + 1) \dots (R_{t-k+1} + 1) = \frac{P_t}{P_{t-1}} \frac{P_{t-1}}{P_{t-2}} \frac{P_{t-2}}{P_{t-3}} \dots \frac{P_{t-k+1}}{P_{t-k}} = \frac{P_t}{P_{t-k}}. \quad (4.10)$$

Logaritmická transformace tohoto výnosu má normální rozdělení a je rovna součtu k logaritmovaných jednoduchých výnosů, tj.


$$r_t(k) = r_t + r_{t-1} + r_{t-2} + \dots + r_{t-k+1}. \quad (4.11)$$

V předkládané práci budeme tedy pracovat s logaritmy denních výnosů indexů BUX, WIG, SAX a PX s ohledem na pravděpodobnostní rozdělení výnosů definovaného dle vztahu 4.9.


Pro zjištění charakteristických vlastností zkoumaných finančních časových řad slouží výpočet popisné statistiky. Tyto statistiky podávají informace o šikmosti a špičatosti časové řady, střední hodnotě, minimálních a maximálních hodnotách, a také směrodatné odchylce a rozptylu.

Výpočty jsou provedeny v prostředí SPSS a EViews.

Obrázek 4.1 *Histogramy logaritmů denních výnosů vybraných indexu za 1. období*



Obrázek 4.2 Histogramy logaritmů denních výnosů vybraných indexů za 2. období



Tab. 4.4 Výběrové statistiky časových řad logaritmů výnosů indexů BUX, WIG, SAX a PX za první období

	N	Minimum	Maximum	Mean	Std. Deviation	Variance	Skewness		Kurtosis	
	Statistic	Statistic	Statistic	Statistic	Statistic	Statistic	Statistic	Std. Error	Statistic	Std. Error
BUX_1	955	-,056027	,048660	,00090191	,013150847	,000	-,268	,079	1,381	,158
WIG_1	955	-,063059	,044638	,00086743	,011127622	,000	-,534	,079	2,654	,158
SAX_1	955	-,046703	,040738	,00096399	,009450937	,000	-,187	,079	4,758	,158
PX_1	955	-,061250	,070482	,00083627	,011064370	,000	-,597	,079	5,219	,158
Valid N	955									

Tab. 4.5 Výběrové statistiky časových řad logaritmů výnosů indexu BUX, WIG, SAX a PX za druhé období

	N	Minimum	Maximum	Mean	Std. Deviation	Variance	Skewness		Kurtosis	
	Statistic	Statistic	Statistic	Statistic	Statistic	Statistic	Statistic	Std. Error	Statistic	Std. Error
BUX_2	959	-,126489	,131777	-,00014339	,020368557	,000	-,101	,079	5,987	,158
WIG_2	959	-,082888	,060837	-,00009972	,016422314	,000	-,323	,079	2,198	,158
SAX_2	959	-,095775	,118803	-,00046368	,010690336	,000	-,451	,079	32,702	,158
PX_2	959	-,161855	,123641	-,00030276	,020257795	,000	-,463	,079	11,117	,158
Valid N	959									

V Tab. 4.4 a 4.5 jsou zobrazeny výsledky základních výběrových charakteristik časových řad logaritmů denních výnosů indexu BUX, WIG, SAX a PX, přičemž v Tab. 4.4 jsou výběrové charakteristiky za 1. období a v Tab. 4.5 jsou charakteristiky za druhé období.

V případě normálního rozdělení by byla hodnota šikmosti 0, lze tedy konstatovat, že v případě zvolených osmi časových řad, u kterých je hodnota šikmosti záporná se jedná o mírné zešikmení doprava. Toto zešikmení je vidět i v histogramech všech osmi časových řad, viz Obr. 4.1 a 4.2.

Co se týče hodnot špičatosti, tak u normálního rozdělení má špičatost hodnotu 3. V prvním období lze tedy pozorovat u časové řady BUX_1 a WIG_1, že v jejich histogramu mají nižší špičku a jsou spíše ploššího charakteru, stejné charakteristické rysy má v druhém období WIG_2. Tento charakteristický rys nevyplyvá pouze z histogramů, ale rovněž z Tab. 4.4 a 4.5, kde jsou hodnoty špičatosti u těchto časových řad nižší než tři. V případě časových řad BUX_1, WIG_1 a WIG_2 to znamená, že se nízké kladné a záporné hodnoty výnosů objevují méně často, než předpokládá normální rozdělení, přičemž nejméně se budou vyskytovat u časové řady BUX_1, kde je hodnota špičatosti 1,381.

V případě ostatních časových řad, kde je hodnota špičatosti větší než tři, dochází k opačnému jevu, a tedy nízké kladné a záporné hodnoty výnosů se objevují častěji, než předpokládá normální rozdělení. Tyto časové řady jsou rovněž charakteristické vyšší špičkou a strmostí. Nejvyšší hodnotu špičatosti má pak časová řada SAX_2, jejíž špičatost má hodnotu 32,702.

Tato rozdělení mají také „tlustší“ konce než normální rozdělení, což znamená, že četnost výskytu extrémně vysokých kladných či záporných výnosů je vyšší než za předpokladu

normality. Pro výpočet šikmosti a špičatosti by bylo možné použít vzorec 2.1 a 2.2, viz kapitola 2.1.

Vzhledem k tomu, že střední hodnoty v 1. období jsou u všech čtyř časových řad velmi malé kladné číslo, pak lze konstatovat, že skutečné rozdělení je zešikmené tak, že se kladné výnosy objevují častěji než výnosy kladné. Naopak ve 2. období jsou střední hodnoty všech čtyř časových velmi malým záporným číslem, a to tedy znamená, že skutečné rozdělení je zešikmené tak, že se záporné výnosy objevují častěji než výnosy kladné.

Jelikož výše uvedené skutečnosti nasvědčují tomu, že logaritmy denních výnosů za první i druhé období nemají normální rozdělení, je nutné tuto hypotézu potvrdit pomocí testu normality. V případě této diplomové práce byl použit Jarque-Bera test, viz kapitola 3.7.

Tab. 4.6 *Jarque-Bera test normality výnosů*

	Jarque-Bera statistika	Pravděpodobnost
BUX_1	85.81048	0.000000
WIG_1	321.2031	0.000000
SAX_1	894.5583	0.000000
PX_1	1126.635	0.000000
BUX_2	1416.185	0.000000
WIG_2	206.5760	0.000000
SAX_2	42305.18	0.000000
PX_2	4915.650	0.000000

Z Tab. 4.6 je patrné, že hodnoty Jarque-Bera statistiky jsou ve všech případech statisticky významné. To tedy znamená, že ve všech obdobích zamítáme hypotézu o normálním rozdělení logaritmu denních výnosů všech čtyř indexů.

Vzhledem k těmto výsledkům je možné přijmout skutečnost, že nepodmíněné rozdělení logaritmů výnosů je kombinací normálních rozdělení, z nichž ta s malým podmíněným rozptylem koncentrují výnosy v blízkosti střední hodnoty a jiná s velkým podmíněným rozptylem posouvají výnosy do konců rozdělení. Výsledkem je pak nepodmíněné špičaté rozdělení s „tlustými“ konci, které má konečný rozptyl a momenty vyššího řádu. V distribuci výnosů se zřejmě významně projevuje jejich heteroskedasticita.

4.3 Test stacionarity výnosů

Nutnost provést test stacionarity výnosů vychází z podmínky stacionarity výnosů popsané v kapitole 2.6. Stacionaritu budeme testovat pomocí rozšířeného Dickey-Fullerova testu jednotkovosti kořene, viz kapitola 3.1.

V prostředí softwaru EViews 6.0 byl proveden ADF test jednotkovosti kořene s konstantou a trendem jako exogenními proměnnými a maximální zpoždění bylo stanoveno na hodnotu 21. Nulovou hypotézou je v tomto případě jednotkovost kořene.

Tab. 4.7 *Výsledné hodnoty ADF testu jednotkovosti kořene časových řad 1. a 2. období*

	Hodnota ADF testu	Pravděpodobnost	Kritická hodnota na hladině významnosti		
			1%	5%	10%
BUX_1	-27,89926	0,0000	-3,9677	-3,4145	-3,1294
WIG_1	-29,29457	0,0000			
SAX_1	-30,24141	0,0000			
PX_1	-28,98765	0,0000			
BUX_2	-13,88827	0,0000			
WIG_2	-28,00617	0,0000			
SAX_2	-30,58644	0,0000			
PX_2	-22,79424	0,0000			

Z Tab. 4.7 je patrné, vypočtená hodnota ADF testu je statisticky významná u všech osmi testovaných časových řad. Jelikož se vypočtené hodnoty ADF testu vyskytují v oboru kritických hodnot, pak zamítáme nulovou hypotézu na hladině významnosti 1%, 5% a 10%. Všechny časové řady uvedené v Tab. 4.7 jsou tedy stacionární.

4.4 Test heteroskedasticity

Prvním krokem modelování volatility je testování heteroskedasticity, viz kapitola 3.5. Pro testování heteroskedasticity lineárního typu je nutné nejdříve odhadnout parametry u lineárního nebo nelineárního úrovnového modelu a získat rezidua. Dále pak pomocí regrese konstruujeme regresní model. Zjištěná rezidua se dále testují na přítomnost heteroskedasticity pomocí ARCH – LM testu, viz kapitola 3.7, v jehož případě se za závisle proměnnou považuje čtverec reziduí a nezávisle proměnnými je konstanta a zpožděné čtverce reziduí. V tomto případě bylo aplikováno zpoždění o 1, 2, 3 a 4 dny. Jako nulová hypotéza je stanovena homoskedasticita. Alternativní hypotézou je pak heteroskedasticita.

Tab. 4.8 ARCH – LM test heteroskedasticity výnosů

	RESID^2 (-1)	Prob.	RESID^2 (-2)	Prob.	RESID^2 (-3)	Prob.	RESID^2 (-4)	Prob.
BUX_1	2,341668	0,0000*	1,870918	0,0617	4,001238	0,0001*	4,7802104	0,0000*
WIG_1	0,330521	0,7411	1,143850	0,2530	1,768356	0,0773	6,340317	0,0000*
SAX_1	1,370395	0,1709	1,748521	0,0807	6,177648	0,0000*	0,776517	0,4376
PX_1	1,972650	0,0488*	5,354539	0,0000*	1,811379	0,0704	1,884575	0,0598
BUX_2	9,025963	0,0000*	3,841140	0,0001*	0,805618	0,4207	1,735048	0,0831
WIG_2	-0,491594	0,6231	2,299516	0,0217*	5,373843	0,0000*	6,908188	0,0000*
SAX_2	0,519673	0,6034	-0,059507	0,9526	0,654911	0,5127	0,234453	0,8147
PX_2	5,690905	0,0000*	4,225706	0,0000*	6,259981	0,0000*	3,668327	0,0003*

V Tab. 4.8 jsou popsány t-statistiky čtverců reziduí se zpožděním 1, 2, 3 a 4 dne včetně koeficientů statistické významnosti. Pokud je statistická významnost pod 5% hranicí, pak zamítáme nulovou hypotézu. V opačném případě nulovou hypotézu přijímáme. Ve všech zkoumaných časových řadách s výjimkou SAX_2 bylo zjištěno, že alespoň v jednom případě je hodnota pravděpodobnosti u zpožděných čtverců reziduí nižší než 5%, a to tedy znamená, že u takovýchto časových řad bude zamítnuta nulová hypotéza.

Závěrem je tedy, že všechny zkoumané časové řady z Tab. 4.8 s výjimkou SAX_2 jsou heteroskedastické tzn., že se rozptýl jejich reziduí mění. U časové řady SAX_2 nebyla zjištěna heteroskedasticita lineárního typu, avšak to neznamená, že se u ní nevyskytuje heteroskedasticita nelineárního typu.

4.5 Odhad lineárního nebo nelineárního modelu volatility

S využitím teoretických znalostí z kapitoly 3.4 až 3.6 o lineárních a nelineárních modelech byl na základě získaných údajů proveden v prostředí softwaru EViews odhad lineárních a nelineárních modelů. Z výsledných odhadů byl ke každé zkoumané časové řadě vybrán nejlepší lineární a nelineární model, přičemž jako kritérium hrála roli nejen pravděpodobnost, ale také Akaikeho a Schwartzovo kritérium, viz vztah 3.52 a 3.53.

Pro zjednodušení byla jako závisle proměnná stanovena zkoumaná časová řada a nezávisle proměnnou byla konstanta. V případě výskytu autokorelace v modelu, byla do modelu zahrnuta i nezávisle proměnná v podobě časové řady zpožděné o jedno období. V situaci kdy v modelu nebude zjištěna statistická významnost nějaké nezávislé proměnné, bude tato proměnná pokud možno z regresní rovnice vyloučena. Odhady budou provedeny s využitím normálního rozdělení pravděpodobnosti, ale je možné pracovat i se Studentovým rozdělením

apod. Z důvodu rozsáhlosti této kapitoly budou jednotlivé modely členěny dle zemí a období s cílem zajistit lepší přehlednost modelů.

4.5.1 Maďarsko

V této podkapitole budou popsány výsledky odhadu lineárních a nelineárních modelů za zkoumané první a druhé období. Časová řada indexu BUX za první období je označena jako BUX_1 a za druhé období BUX_2.

a) 1. období

Na základě provedených odhadů lineárních a nelineárních modelů volatility byl pro časovou řadu BUX_1 vybrán jako nejlepší lineární model GARCH(1,1), viz Tab. 4.9 vlevo, a nejlepší nelineární model EGARCH(1,1), viz Tab. 4.9 vpravo. Z tabulky je rovněž patrné, že všechny proměnné jsou statisticky významné, stejně tak je významný i parametr asymetričnosti informací $C4$ u nelineárního modelu.

Tab. 4.9 Odhad lineárního modelu GARCH(1,1) a nelineárního modelu EGARCH(1,1) pro časovou řadu BUX_1

GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*GARCH(-1)				
	Coefficient	Std. Error	z-Statistic	Prob.
C	0.001206	0.000389	3.096747	0.0020
BUX_1(-1)	0.075976	0.034660	2.192058	0.0284
Variance Equation				
C	7.98E-06	2.66E-06	2.993733	0.0028
RESID(-1)^2	0.098510	0.020236	4.868035	0.0000
GARCH(-1)	0.855135	0.029027	29.46011	0.0000
R-squared	0.008837	Mean dependent var	0.000897	
Adjusted R-squared	0.004659	S.D. dependent var	0.013157	
S.E. of regression	0.013126	Akaike info criterion	-5.920278	
Sum squared resid	0.163506	Schwarz criterion	-5.894803	
Log likelihood	2828.973	Hannan-Quinn criter.	-5.910574	
F-statistic	2.115310	Durbin-Watson stat	1.943673	
Prob(F-statistic)	0.076957			

LOG(GARCH) = C(3) + C(4)*ABS(RESID(-1))/SQRT(GARCH(-1)) + C(5)*RESID(-1)/SQRT(GARCH(-1)) + C(6)*LOG(GARCH(-1))				
	Coefficient	Std. Error	z-Statistic	Prob.
C	0.001082	0.000395	2.739837	0.0061
BUX_1(-1)	0.079205	0.034253	2.312330	0.0208
Variance Equation				
C(3)	-0.660846	0.164360	-4.020723	0.0001
C(4)	0.203281	0.034164	5.950212	0.0000
C(5)	-0.037587	0.017671	-2.127038	0.0334
C(6)	0.942622	0.017495	53.87819	0.0000
R-squared	0.009437	Mean dependent var	0.000897	
Adjusted R-squared	0.004212	S.D. dependent var	0.013157	
S.E. of regression	0.013129	Akaike info criterion	-5.917792	
Sum squared resid	0.163407	Schwarz criterion	-5.887221	
Log likelihood	2828.787	Hannan-Quinn criter.	-5.906146	
F-statistic	1.806222	Durbin-Watson stat	1.950880	
Prob(F-statistic)	0.108962			

b) 2. období

Odhadem lineárního modelu volatility, který měl nejlepší hodnoty požadovaných informačních kritérií a zároveň koeficienty rovnice rozptylu byly statisticky významné, je model GARCH(1,1) s normálním rozdělením pravděpodobnosti, viz Tab. 4.10 vlevo.

Nejlepším odhadnutým nelineárním modelem pak byl model EGARCH(1,1), jehož odhad je zobrazen v Tab. 4.10 vpravo. Parametr asymetričnosti $C3$ je u modelu EGARCH(1,1) opět statisticky významný.

Tab. 4.10 Odhad lineárního modelu GARCH(1,1) a nelineárního modelu EGARCH(1,1) pro časovou řadu BUX_2

GARCH = C(2) + C(3)*RESID(-1)^2 + C(4)*GARCH(-1)				
	Coefficient	Std. Error	z-Statistic	Prob.
BUX_2(-1)	0.068117	0.032502	2.095775	0.0361
Variance Equation				
C	4.93E-06	1.60E-06	3.071152	0.0021
RESID(-1)^2	0.116759	0.016836	6.935174	0.0000
GARCH(-1)	0.872936	0.017046	51.20949	0.0000
R-squared	0.009743	Mean dependent var	-0.000144	
Adjusted R-squared	0.006628	S.D. dependent var	0.020379	
S.E. of regression	0.020312	Akaike info criterion	-5.339134	
Sum squared resid	0.393582	Schwarz criterion	-5.318822	
Log likelihood	2561.445	Hannan-Quinn criter.	-5.331398	
Durbin-Watson stat	1.906096			

LOG(GARCH) = C(2) + C(3)*ABS(RESID(-1)/@SQRT(GARCH(-1))) + C(4)*RESID(-1)/@SQRT(GARCH(-1)) + C(5)*LOG(GARCH(-1))				
	Coefficient	Std. Error	z-Statistic	Prob.
BUX_2(-1)	0.077137	0.031009	2.487580	0.0129
Variance Equation				
C(2)	-0.267963	0.046368	-5.779101	0.0000
C(3)	0.188699	0.024911	7.575053	0.0000
C(4)	-0.065023	0.014496	-4.485575	0.0000
C(5)	0.985162	0.004594	214.4580	0.0000
R-squared	0.010344	Mean dependent var	-0.000144	
Adjusted R-squared	0.006190	S.D. dependent var	0.020379	
S.E. of regression	0.020316	Akaike info criterion	-5.342205	
Sum squared resid	0.393343	Schwarz criterion	-5.316814	
Log likelihood	2563.916	Hannan-Quinn criter.	-5.332535	
Durbin-Watson stat	1.921850			

4.5.2 Polsko

V této podkapitole budou popsány výsledky odhadu lineárních a nelineárních modelů za zkoumané první a druhé období zjištěných na základě časové řady indexu WIG. První období je tedy označeno jako WIG_1 a za druhé období WIG_2.

a) 1. období

Ze zjištěných odhadů lineárních modelů volatility byl jako nejlepší lineární model vybrán pro časovou řadu WIG_1 model IGARCH(1,2) s normálním rozdělením pravděpodobnosti a významnými koeficienty, viz Tab. 4.11 vlevo. Jako nejlepší model mezi zkoumanými nelineárními modely se jeví model EGARCH(0,1), jehož odhad je zobrazen v Tab. 4.11 vpravo.

Tab. 4.11 Odhad lineárního modelu IGARCH(1,2) a nelineárního modelu EGARCH(0,1) pro časovou řadu WIG_1

GARCH = C(3)*RESID(-1)^2 + C(4)*GARCH(-1) + (1 - C(3) - C(4))*GARCH(-2)				
	Coefficient	Std. Error	z-Statistic	Prob.
C	0.000891	0.000255	3.494860	0.0005
WIG_1(-1)	0.069802	0.030301	2.303601	0.0212
Variance Equation				
RESID(-1)^2	0.026363	0.006832	3.858778	0.0001
GARCH(-1)	1.679011	0.088966	18.87253	0.0000
GARCH(-2)	-0.705374	0.082737	-8.525504	0.0000
R-squared	0.002257	Mean dependent var	0.000862	
Adjusted R-squared	-0.000893	S.D. dependent var	0.011132	
S.E. of regression	0.011137	Akaike info criterion	-6.258219	
Sum squared resid	0.117833	Schwarz criterion	-6.237839	
Log likelihood	2989.171	Hannan-Quinn criter.	-6.250456	
F-statistic	0.716461	Durbin-Watson stat	2.042184	
Prob(F-statistic)	0.542246			

LOG(GARCH) = C(3) + C(4)*RESID(-1)/@SQRT(GARCH(-1)) + C(5)*LOG(GARCH(-1))				
	Coefficient	Std. Error	z-Statistic	Prob.
C	0.000849	0.000372	2.283730	0.0224
WIG_1(-1)	0.070865	0.033754	2.099464	0.0358
Variance Equation				
C(3)	-2.399626	0.541303	-4.433053	0.0000
C(4)	-0.154395	0.034934	-4.419574	0.0000
C(5)	0.734541	0.059899	12.26290	0.0000
R-squared	0.002262	Mean dependent var	0.000862	
Adjusted R-squared	-0.001943	S.D. dependent var	0.011132	
S.E. of regression	0.011143	Akaike info criterion	-6.187991	
Sum squared resid	0.117833	Schwarz criterion	-6.162515	
Log likelihood	2956.672	Hannan-Quinn criter.	-6.178286	
F-statistic	0.537956	Durbin-Watson stat	2.044531	
Prob(F-statistic)	0.707890			

b) 2. období

Nejlepším lineárním odhadem modelu volatility na základě časové řady WIG_2 je model GARCH(2,2) s normálním rozdělením pravděpodobnosti, viz Tab. 4.12 vlevo. Jako nejlepší nelineární model byl vybrán EGARCH(2,1), viz Tab. 4.12 vpravo. Rovnice rozptylu modelu je statisticky významná stejně tak parametr asymetričnosti informací.

Tab. 4.12 Odhad lineárního modelu IGARCH(1,2) a nelineárního modelu EGARCH(2,1) pro časovou řadu WIG_2

GARCH = C(2)*RESID(-1)^2 + C(3)*GARCH(-1) + (1 - C(2) - C(3)) *GARCH(-2)				
	Coefficient	Std. Error	z-Statistic	Prob.
WIG_2(-1)	0.089389	0.031183	2.866597	0.0041
Variance Equation				
RESID(-1)^2	0.038165	0.014696	2.597004	0.0094
GARCH(-1)	1.498558	0.199412	7.514901	0.0000
GARCH(-2)	-0.536723	0.185211	-2.897907	0.0038
R-squared	0.009518	Mean dependent var	-9.98E-05	
Adjusted R-squared	0.007444	S.D. dependent var	0.016431	
S.E. of regression	0.016370	Akaike info criterion	-5.506035	
Sum squared resid	0.255907	Schwarz criterion	-5.490800	
Log likelihood	2640.391	Hannan-Quinn criter.	-5.500232	
Durbin-Watson stat	1.978488			

LOG(GARCH) = C(2) + C(3)*ABS(RESID(-1))/@SQRT(GARCH(-1))) + C(4) *ABS(RESID(-2))/@SQRT(GARCH(-2))) + C(5)*RESID(-1) /@SQRT(GARCH(-1)) + C(6)*LOG(GARCH(-1))				
	Coefficient	Std. Error	z-Statistic	Prob.
WIG_2(-1)	0.103229	0.024507	4.212224	0.0000
Variance Equation				
C(2)	-0.419775	0.090274	-4.649981	0.0000
C(3)	-0.272103	0.068298	-3.984071	0.0001
C(4)	0.421218	0.067562	6.234513	0.0000
C(5)	-0.087726	0.017278	-5.077367	0.0000
C(6)	0.963857	0.010106	95.37163	0.0000
R-squared	0.009568	Mean dependent var	-9.98E-05	
Adjusted R-squared	0.004367	S.D. dependent var	0.016431	
S.E. of regression	0.016395	Akaike info criterion	-5.554477	
Sum squared resid	0.255893	Schwarz criterion	-5.524008	
Log likelihood	2666.594	Hannan-Quinn criter.	-5.542872	
Durbin-Watson stat	2.005561			

4.5.3 Slovensko

I v této podkapitole budou popsány nejlepší odhadnuté lineární a nelineární modely volatility za první a druhé období, tedy za časové řady SAX_1 a SAX_2.

a) 1. období

Nejlepším odhadem časové řady SAX_1 ze skupiny lineárních modelů byl IGARCH(2,2) model, viz Tab. 4.13 vlevo. Co se týká nejlepšího nelineárního modelu, tak je jím EGARCH-M(0,1). Odhad tohoto modelu je k dispozici v Tab. 4.13 vpravo.

Tab. 4.13 Odhad lineárního modelu IGARCH(2,2) a nelineárního modelu EGARCH-M(0,1) pro časovou řadu SAX_1

GARCH = C(3)*RESID(-1)^2 + C(4)*RESID(-2)^2 + C(5)*GARCH(-1) + (1 - C(3) - C(4) - C(5))*GARCH(-2)					LOG(GARCH) = C(3) + C(4)*RESID(-1)*@SQRT(GARCH(-1)) + C(5)*LOG(GARCH(-1))				
	Coefficient	Std. Error	z-Statistic	Prob.		Coefficient	Std. Error	z-Statistic	Prob.
C	0.000425	0.000258	1.646643	0.0996	@SQRT(GARCH)	0.779785	0.253994	3.070093	0.0021
SAX_1(-1)	0.068764	0.023419	2.936193	0.0033	C	-0.006314	0.002273	-2.777231	0.0055
Variance Equation					Variance Equation				
RESID(-1)^2	0.063961	0.007825	8.173801	0.0000	C(3)	-0.232554	0.065428	-3.554361	0.0004
RESID(-2)^2	-0.062937	0.007675	-8.200441	0.0000	C(4)	0.040452	0.005999	6.742971	0.0000
GARCH(-1)	1.870284	0.021944	85.22801	0.0000	C(5)	0.975377	0.006967	139.9942	0.0000
GARCH(-2)	-0.871308	0.021671	-40.20685	0.0000					
R-squared	0.001493	Mean dependent var	0.000923		R-squared	0.020785	Mean dependent var	0.000964	
Adjusted R-squared	0.005714	S.D. dependent var	0.009371		Adjusted R-squared	0.016662	S.D. dependent var	0.009451	
S.E. of regression	0.009398	Akaike info criterion	-6.620354		S.E. of regression	0.009372	Akaike info criterion	-6.535186	
Sum squared resid	0.083817	Schwarz criterion	-6.594879		Sum squared resid	0.083440	Schwarz criterion	-6.509732	
Log likelihood	3162.909	Hannan-Quinn criter.	-6.610650		Log likelihood	3125.551	Hannan-Quinn criter.	-6.525490	
Durbin-Watson stat	2.058935				F-statistic	5.041113	Durbin-Watson stat	1.975315	
					Prob(F-statistic)	0.000505			

b) 2. období

Pro časovou řadu SAX_2 byl proveden odhad lineárního modelu a výsledným nejlepším modelem byl IGARCH-M(2,2), jehož koeficienty rovnice rozptylu jsou statisticky významné, stejně jako je významný parametr směrodatné odchylky. Odhad modelu je zobrazen v Tab. 4.14 vlevo. V případě nelineárního odhadu modelu volatility byl nejlepším odhadnutým modelem EGARCH-M(1,2), viz Tab. 4.14 vpravo. Rovnice rozptylu tohoto modelu má statisticky významné koeficienty. Statisticky významný je i parametr směrodatné odchylky hlavní rovnice.

Tab. 4.14 Odhad lineárního modelu IGARCH-M(2,2) a nelineárního modelu EGARCH-M(1,2) pro časovou řadu SAX_2

GARCH = C(3)*RESID(-1)^2 + C(4)*RESID(-2)^2 + C(5)*GARCH(-1) + (1 - C(3) - C(4) - C(5))*GARCH(-2)					LOG(GARCH) = C(3) + C(4)*ABS(RESID(-1))*@SQRT(GARCH(-1)) + C(5)*RESID(-1)*@SQRT(GARCH(-1)) + C(6)*LOG(GARCH(-1)) + C(7)*LOG(GARCH(-2))				
	Coefficient	Std. Error	z-Statistic	Prob.		Coefficient	Std. Error	z-Statistic	Prob.
@SQRT(GARCH)	0.206293	0.064533	3.196701	0.0014	@SQRT(GARCH)	0.292282	0.066647	4.385562	0.0000
C	0.001324	0.000510	2.598423	0.0094	C	0.002169	0.000447	4.851218	0.0000
Variance Equation					Variance Equation				
RESID(-1)^2	0.064104	0.008326	7.699063	0.0000	C(3)	-0.031580	0.011009	-2.868648	0.0041
RESID(-2)^2	-0.040835	0.009944	-4.106346	0.0000	C(4)	0.106123	0.014254	7.444961	0.0000
GARCH(-1)	0.431594	0.108361	3.982917	0.0001	C(5)	-0.041757	0.007055	-5.918692	0.0000
GARCH(-2)	0.545137	0.106440	5.121526	0.0000	C(6)	0.381050	0.178047	2.140159	0.0323
					C(7)	0.621403	0.178563	3.480013	0.0005
R-squared	0.000121	Mean dependent var	-0.000464		R-squared	0.006639	Mean dependent var	-0.000464	
Adjusted R-squared	0.004071	S.D. dependent var	0.010690		Adjusted R-squared	0.012983	S.D. dependent var	0.010690	
S.E. of regression	0.010712	Akaike info criterion	-6.481337		S.E. of regression	0.010759	Akaike info criterion	-6.464602	
Sum squared resid	0.109470	Schwarz criterion	-6.455968		Sum squared resid	0.110210	Schwarz criterion	-6.429085	
Log likelihood	3112.801	Hannan-Quinn criter.	-6.471676		Log likelihood	3106.777	Hannan-Quinn criter.	-6.451076	
F-statistic	0.028972	Durbin-Watson stat	1.981277		Durbin-Watson stat	1.980225			
Prob(F-statistic)	0.998382								

4.5.4 ČR

Tato podkapitola se věnuje nejlepším lineárním a nelineárním odhadům modelu volatility časové řady PX_1 a PX_2.

a) 1. období

Nejlepším odhadem lineárního modelu volatility u časové řady PX_1 je GARCH(1,2), který je zobrazen v Tab. 4.15 vlevo. Nejlepším nelineárním modelem byl EGARCH-M(1,1), jehož koeficienty rovnice rozptylu jsou statisticky významné stejně tak jako parametr asymetričnosti informací C4, viz Tab. 4.15 vpravo.

Tab. 4.15 Odhad nelineárního modelu GARCH(1,2) a nelineárního modelu EGARCH-M(1,1) pro časovou řadu PX_1

GARCH = C(2) + C(3)*RESID(-1)^2 + C(4)*GARCH(-1) + C(5)*GARCH(-2)				
	Coefficient	Std. Error	z-Statistic	Prob.
C	0.001200	0.000299	4.010773	0.0001
Variance Equation				
C	2.50E-06	8.73E-07	2.865141	0.0042
RESID(-1)^2	0.050903	0.013987	3.639390	0.0003
GARCH(-1)	1.521857	0.132352	11.49856	0.0000
GARCH(-2)	-0.592292	0.114155	-5.188477	0.0000
R-squared	0.001084	Mean dependent var		0.000836
Adjusted R-squared	0.005299	S.D. dependent var		0.011064
S.E. of regression	0.011094	Akaike info criterion		-6.337361
Sum squared resid	0.116915	Schwarz criterion		-6.311907
Log likelihood	3031.090	Hannan-Quinn criter.		-6.327665
Durbin-Watson stat	1.863664			

LOG(GARCH) = C(3) + C(4)*ABS(RESID(-1)/@SQRT(GARCH(-1))) + C(5)*RESID(-1)/@SQRT(GARCH(-1)) + C(6)*LOG(GARCH(-1))				
	Coefficient	Std. Error	z-Statistic	Prob.
@SQRT(GARCH)	0.088845	0.033494	2.652561	0.0080
PX_1(-1)	0.075649	0.038290	1.975676	0.0482
Variance Equation				
C(3)	-1.207654	0.209246	-5.771452	0.0000
C(4)	0.200936	0.035018	5.738051	0.0000
C(5)	-0.164893	0.028711	-5.743104	0.0000
C(6)	0.885594	0.021616	40.96920	0.0000
R-squared	0.003643	Mean dependent var		0.000859
Adjusted R-squared	0.001612	S.D. dependent var		0.011047
S.E. of regression	0.011056	Akaike info criterion		-6.364438
Sum squared resid	0.115881	Schwarz criterion		-6.333868
Log likelihood	3041.837	Hannan-Quinn criter.		-6.352792
Durbin-Watson stat	2.001201			

b) 2. období

V případě odhadu lineárního modelu volatility časové řady PX_2 byl nejlepším modelem IGARCH(1,1), viz Tab. 4.16 vlevo. Nejlepší variantou nelineárního modelu volatility je pak model EGARCH(1,2) s významným parametrem asymetričnosti C3, viz Tab. 4.16 vpravo.

Tab. 4.16 Odhad lineárního modelu IGARCH(1,1) a nelineárního modelu EGARCH(1,2) pro časovou řadu PX_2

GARCH = C(2)*RESID(-1)^2 + (1 - C(2))*GARCH(-1)				
	Coefficient	Std. Error	z-Statistic	Prob.
C	0.000450	0.000289	1.555669	0.1198
Variance Equation				
RESID(-1)^2	0.126589	0.010444	12.12037	0.0000
GARCH(-1)	0.873411	0.010444	83.62577	0.0000
R-squared	0.001382	Mean dependent var	-0.000303	
Adjusted R-squared	0.002428	S.D. dependent var	0.020258	
S.E. of regression	0.020282	Akaike info criterion	-5.517016	
Sum squared resid	0.393686	Schwarz criterion	-5.506868	
Log likelihood	2647.409	Hannan-Quinn criter.	-5.513151	
Durbin-Watson stat	1.805505			

LOG(GARCH) = C(2) + C(3)*ABS(RESID(-1))/SQRT(GARCH(-1)) + C(4)*RESID(-1)/SQRT(GARCH(-1)) + C(5)*LOG(GARCH(-1)) + C(6)*LOG(GARCH(-2))				
	Coefficient	Std. Error	z-Statistic	Prob.
PX_2(-1)	0.066323	0.033888	1.957156	0.0499
Variance Equation				
C(2)	-0.332074	0.074350	-4.466344	0.0000
C(3)	0.208838	0.043880	4.759332	0.0000
C(4)	-0.067934	0.017841	-3.807768	0.0001
C(5)	1.291791	0.139075	9.288446	0.0000
C(6)	-0.312315	0.135759	-2.300512	0.0214
R-squared	0.008140	Mean dependent var	-0.000303	
Adjusted R-squared	0.002931	S.D. dependent var	0.020268	
S.E. of regression	0.020239	Akaike info criterion	-5.562167	
Sum squared resid	0.389942	Schwarz criterion	-5.531698	
Log likelihood	2670.278	Hannan-Quinn criter.	-5.550562	
Durbin-Watson stat	1.927461			

4.6 Testování reziduí odhadnutých modelů

Dalším krokem následujícím po odhadu nejlepších lineárních a nelineárních modelů volatility je ověření jejich vhodnosti, viz kapitola 3.7. Odhady nejlepších modelů volatility z kapitoly 4.5 budou podrobeny testem heteroskedasticity, normality a autokorelace. Rezidua by měla být normálně rozdělena, homoskedastická a neautokorelovaná. Výsledky těchto diagnostických testů, pak přináší informace o tom, zda model vyhovuje na něj kladeným podmínkám či nikoliv.


4.6.1 Testování normality

Tento test byl již jednou proveden v kapitole 4.2, avšak tentokrát pracujeme s nejlepšími odhadnutými modely z kapitoly 4.5. V této podkapitole tedy budou opět pomocí histogramů a výběrových charakteristik jednotlivé modely charakterizovány. V jednotlivých obrázcích se nachází vždy 2 modely, vlevo vždy model lineární a vpravo model nelineární.


a) Maďarsko

Prvními charakterizovanými modely jsou nejlepší lineární a nelineární modely BUX za první a druhé období. Histogram včetně popisné statistiky k daným modelům je zobrazen na obrázku 4.3 a 4.4

Obrázek 4.3 Histogram reziduí časové řady BUX_1 pro model GARCH(1,1) a EGARCH(1,1)



Obrázek 4.4 Histogram reziduí časové řady BUX_2 pro model GARCH(1,1) a EGARCH(1,1)




Z obrázku 4.3 a 4.4 je patrné, že u modelů prvního období je viditelné velmi mírné zešíkvení doprava, rozdělení je rovněž špičatější a strmější, než v případě normálního rozdělení. Z toho vyplývá, že se nízké kladné a záporné hodnoty budou objevovat častěji než za předpokladu normality. U modelů druhého období je vidět mírné zešíkvení doleva.

Co se týká špičatosti, je nižší než v prvním období, avšak interpretace je stejná. Hodnoty pravděpodobnosti u Jarque-Bera testu jsou menší než 5%, to tedy znamená, že u modelů není splněn předpoklad normality, avšak normálnímu rozdělení se blíží. Ve všech čtyřech modelech je střední hodnota velmi nízké záporné číslo tzn., že se v těchto modelech záporné výnosy objevují častěji než kladné výnosy.


b) Polsko

Nejlépejší lineární a nelineární modely volatility časové řady WIG_1 a WIG_2 jsou dalšími modely, u kterých je nutné otestovat normalitu. Histogram včetně popisné statistiky k daným modelům je zobrazen na obrázku 4.5 a 4.6.

Obrázek 4.5 Histogram reziduí časové řady *WIG_1* pro model *IGARCH(1,2)* a *EGARCH(0,1)*



Obrázek 4.6 Histogram reziduí časové řady *WIG_2* pro model *IGARCH(1,2)* a *EGARCH(2,1)*




Na obrázku 4.5 a 4.6 je vidět, že u všech modelů za první i druhé období je šikmost malé záporné číslo, což představuje mírné zešikmení doprava. Rozdělení pravděpodobnosti je rovněž ve všech případech špičatější a strmější, než jak je tomu u normálního rozdělení. Z toho vyplývá, že se nízké kladné a záporné hodnoty budou objevovat častěji než za předpokladu normality. U modelu *EGARCH(0,1)* je pak zřejmé, že se nízké kladné a záporné hodnoty budou objevovat mnohem častěji než u ostatních tří modelů, jelikož je zde hodnota špičatosti 5,0114.

Hodnoty pravděpodobnosti u Jarque-Bera testu jsou opět menší než 5%, a tedy u těchto modelů není splněn předpoklad normality. V modelu *IGARCH(1,2)* za první období je střední hodnota kladná, tudíž lze předpokládat, že v modelu kladné výnosy převažují nad výnosy zápornými. V ostatních modelech je situace opačná.


c) Slovensko

Nejlepší odhady lineárních a nelineárních modelů časové řady *SAX* za první a druhé období se také podrobují testu normality, viz obrázek 4.7 a 4.8.

Obrázek 4.7 Histogram reziduí časové řady *SAX_1* pro model *IGARCH(2,2)* a *EGARCH-M(0,1)*



Obrázek 4.8 Histogram reziduí časové řady *SAX_2* pro model *IGARCH-M(2,2)* a *EGARCH-M(1,2)*




Z obrázku 4.7 a 4.8 je možné konstatovat, že u všech čtyř modelů je šikmost záporná, rozdělení pravděpodobnosti je u nich tedy zešikmeno doprava. Rozdělení pravděpodobnosti je rovněž ve všech případech špičatější a strmější, než jak je tomu u normálního rozdělení. V případě těchto modelů tedy platí, že se nízké kladné a záporné hodnoty budou objevovat častěji než za předpokladu normality. Hodnota špičatosti ve druhém období je téměř dvojnásobná ve srovnání s obdobím prvním, tedy výskyt nízkých kladných a záporných hodnot bude ve druhém období podstatně vyšší.

Hodnoty pravděpodobnosti v případě Jarque-Bera testu jsou pod 5%, je tedy zamítnuta hypotéza o normálním rozdělení pravděpodobnosti. V modelu *EGARCH-M(0,1)* je střední hodnota záporná, tudíž lze předpokládat, že v modelu záporné výnosy převažují nad kladnými. V ostatních modelech je situace opačná.


d) Česká republika

Posledními testovanými modely na normalitu jsou nejlepší lineární a nelineární modely za 1. a 2. období. Histogram včetně popisné statistiky k daným modelům je zobrazen na obrázku 4.9 a 4.10.

Obrázek 4.9 Histogram reziduí časové řady PX_1 pro model $GARCH(1,2)$ a $EGARCH-M(1,1)$



Obrázek 4.10 Histogram reziduí časové řady PX_2 pro model $IGARCH(1,1)$ a $EGARCH(1,2)$



Z obrázku 4.9 a 4.10 je patrné, že u modelů za první i druhé období je šikmost záporným číslem a tedy rozdělení pravděpodobnosti u těchto modelů je zešikmeno doprava. Špičatost je u všech čtyř modelů rovněž vyšší než v případě normálního rozdělení, a z toho vyplývá, že rozdělení pravděpodobnosti u těchto modelů je špičatější a strmější než u normálního rozdělení. Platí tedy, že se nízké kladné a záporné hodnoty budou objevovat v těchto modelech častěji než za předpokladu normality.

Dle Jarque-Bera testu normality je hypotéza o normálním rozdělení pravděpodobnosti zamítnuta. Co se týká střední hodnoty, ta je u modelů za první i druhé období záporná a nízká, lze tedy říci, že ve všech modelech se záporné výnosy budou objevovat častěji než výnosy kladné.

Po provedení Jarque-Bera testu normality u výše uvedených modelů, lze konstatovat, že ani jeden z nich nesplnil podmínky pro normální rozdělení pravděpodobnosti, jelikož ve všech případech byla hypotéza o normálním rozdělení zamítnuta. Všechny modely za první a druhé období tedy nemají normální rozdělení, ale přes to se tomuto rozdělení blíží.

4.6.2 Test autokorelace

Autokorelace reziduální složky znamená sériovou závislost časové řady reziduí a časové řady zpožděných reziduí. Pro zjištění autokorelace se používají různé testy a grafická vyjádření. V předkládané diplomové práci bude pro zjištění autokorelace použit korelogram, viz kapitola 3.7. V jednotlivých obrázcích této kapitoly budou znázorněny korelogramy standardizovaných reziduí nejlepších lineárních a nelineárních modelů příslušných časových řad za první a druhé období, přičemž se pracuje se zpožděním o 1 až 8 období. Při interpretaci obrázků platí, že tabulky vlevo představují vždy nejlepší lineární modely a tabulky vpravo nejlepší nelineární modely odhadnuté v kapitole 4.5.

a) *Maďarsko*

Tab. 4.17 *Korelogram reziduí lineárního a nelineárního modelu volatility časové řady BUX_1*

	AC	PAC	Q-Stat	Prob
1	0.016	0.016	0.2414	0.623
2	-0.009	-0.009	0.3131	0.855
3	-0.020	-0.020	0.7015	0.873
4	0.007	0.008	0.7489	0.945
5	-0.005	-0.005	0.7712	0.979
6	0.047	0.047	2.9044	0.821
7	-0.039	-0.041	4.3744	0.736
8	-0.022	-0.020	4.8273	0.776

	AC	PAC	Q-Stat	Prob
1	0.016	0.016	0.2414	0.623
2	-0.009	-0.009	0.3131	0.855
3	-0.020	-0.020	0.7015	0.873
4	0.007	0.008	0.7489	0.945
5	-0.005	-0.005	0.7712	0.979
6	0.047	0.047	2.9044	0.821
7	-0.039	-0.041	4.3744	0.736
8	-0.022	-0.020	4.8273	0.776

Tab. 4.18 *Korelogram reziduí lineárního a nelineárního modelu volatility časové řady BUX_2*

	AC	PAC	Q-Stat	Prob
1	0.018	0.018	0.3080	0.579
2	-0.040	-0.040	1.8408	0.398
3	-0.021	-0.019	2.2519	0.522
4	0.069	0.068	6.8115	0.146
5	0.039	0.035	8.3071	0.140
6	-0.069	-0.066	12.943	0.051
7	-0.007	0.001	12.994	0.072
8	0.029	0.021	13.783	0.088

	AC	PAC	Q-Stat	Prob
1	0.009	0.009	0.0717	0.789
2	-0.047	-0.047	2.1557	0.340
3	-0.015	-0.015	2.3837	0.497
4	0.069	0.067	6.9863	0.137
5	0.032	0.030	7.9916	0.157
6	-0.064	-0.059	11.998	0.062
7	-0.005	0.001	12.025	0.100
8	0.031	0.022	12.941	0.114

V Tab. 4.17 vlevo je korelogram lineárního modelu GARCH(1,1) a vpravo je pak korelogram nelineárního modelu EGARCH(1,1). V Tab. 4.18 vlevo je pak korelogram lineárního modelu GARCH(1,1) a vpravo korelogram nelineárního modelu EGARCH(1,1) za období druhé. Z Tab. 4.17 a 4.18 je tedy patrné, že se v žádném modelu nevyskytuje autokorelace. Časové řady reziduí za první a druhé období tedy nejsou závislé na svých zpožděných časových řadách.

b) Polsko

Tab. 4.19 Korelogram reziduí lineárního a nelineárního modelu volatility časové řady *WIG_1*

	AC	PAC	Q-Stat	Prob
1	-0.011	-0.011	0.1079	0.743
2	0.057	0.057	3.1952	0.202
3	-0.011	-0.010	3.3111	0.346
4	0.010	0.006	3.4019	0.493
5	-0.020	-0.019	3.7783	0.582
6	0.007	0.005	3.8230	0.701
7	-0.058	-0.055	7.0114	0.428
8	0.000	-0.002	7.0114	0.535

	AC	PAC	Q-Stat	Prob
1	-0.011	-0.011	0.1079	0.743
2	0.057	0.057	3.1952	0.202
3	-0.011	-0.010	3.3111	0.346
4	0.010	0.006	3.4019	0.493
5	-0.020	-0.019	3.7783	0.582
6	0.007	0.005	3.8230	0.701
7	-0.058	-0.055	7.0114	0.428
8	0.000	-0.002	7.0114	0.535

Tab. 4.20 Korelogram reziduí lineárního a nelineárního modelu volatility časové řady *WIG_2*

	AC	PAC	Q-Stat	Prob
1	0.003	0.003	0.0063	0.937
2	0.015	0.015	0.2117	0.900
3	0.018	0.018	0.5349	0.911
4	0.068	0.068	4.9732	0.290
5	0.031	0.031	5.9294	0.313
6	-0.035	-0.038	7.1178	0.310
7	-0.029	-0.032	7.9205	0.340
8	0.030	0.026	8.8094	0.359

	AC	PAC	Q-Stat	Prob
1	-0.001	-0.001	0.0003	0.986
2	-0.004	-0.004	0.0139	0.993
3	0.011	0.011	0.1285	0.988
4	0.058	0.058	3.3274	0.505
5	0.009	0.009	3.4096	0.637
6	-0.030	-0.029	4.2517	0.643
7	-0.030	-0.031	5.1084	0.647
8	0.021	0.017	5.5384	0.699

V Tab. 4.19 vlevo je korelogram lineárního modelu IGARCH(1,2) a vpravo korelogram nelineárního modelu EGARCH(0,1). V Tab. 4.20 je pak vlevo zobrazen korelogram lineárního modelu IGARCH(1,2) a vpravo korelogram nelineárního modelu EGARCH(2,1). Z výsledných hodnot pravděpodobnosti je patrné, že u žádného modelu se nevyskytuje autokorelace, hypotéza o sériové závislosti reziduí na svých zpožděních je tedy zamítnuta.

c) Slovensko

Tab. 4.21 Korelogram reziduí lineárního a nelineárního modelu volatility časové řady *SAX_1*

	AC	PAC	Q-Stat	Prob
1	-0.056	-0.056	3.0175	0.082
2	0.039	0.036	4.4497	0.108
3	0.012	0.017	4.5975	0.204
4	0.037	0.037	5.9114	0.206
5	0.064	0.068	9.8746	0.079
6	0.023	0.027	10.363	0.110
7	0.016	0.013	10.606	0.157
8	0.043	0.040	12.396	0.134

	AC	PAC	Q-Stat	Prob
1	-0.014	-0.014	0.1979	0.656
2	0.033	0.032	1.2179	0.544
3	-0.030	-0.029	2.1039	0.551
4	0.006	0.004	2.1338	0.711
5	0.064	0.067	6.1154	0.295
6	0.018	0.019	6.4239	0.377
7	-0.004	-0.008	6.4416	0.489
8	0.040	0.043	7.9715	0.436

Tab. 4.22 Korelogram reziduí lineárního a nelineárního modelu volatility časové řady *SAX_2*

	AC	PAC	Q-Stat	Prob
1	-0.002	-0.002	0.0055	0.941
2	-0.017	-0.017	0.2792	0.870
3	-0.048	-0.048	2.5276	0.470
4	-0.042	-0.043	4.2652	0.371
5	0.044	0.042	6.1554	0.291
6	-0.034	-0.038	7.2758	0.296
7	0.001	-0.002	7.2761	0.401
8	-0.005	-0.004	7.3011	0.505

	AC	PAC	Q-Stat	Prob
1	-0.016	-0.016	0.2475	0.619
2	-0.006	-0.007	0.2877	0.866
3	-0.046	-0.046	2.3256	0.508
4	-0.045	-0.047	4.3187	0.365
5	0.045	0.043	6.3048	0.278
6	-0.025	-0.026	6.9064	0.330
7	0.003	-0.002	6.9148	0.438
8	-0.009	-0.008	6.9989	0.537

V Tab. 4.21 vlevo je zobrazen korelogram lineárního modelu IGARCH(2,2) a vpravo korelogram nelineárního modelu EGARCH-M(0,1). V Tab. 4.22 je pak korelogram lineárního modelu *IGARCH-M(2,2)* a vpravo korelogram nelineárního modelu *EGARCH-M(1,2)*. Z těchto dvou tabulek je tedy patrné, že jelikož hodnoty pravděpodobnosti u jednotlivých zpoždění nebyly nižší 5%, pak tedy se u těchto modelů nevyskytuje autokorelace.

d) Česká republika

Tab. 4.23 Korelogram reziduí lineárního a nelineárního modelu volatility časové řady *PX_1*

	AC	PAC	Q-Stat	Prob
1	0.060	0.060	3.4750	0.062
2	-0.022	-0.026	3.9538	0.139
3	-0.019	-0.016	4.3106	0.230
4	0.001	0.002	4.3109	0.366
5	0.017	0.016	4.5886	0.468
6	-0.013	-0.016	4.7565	0.575
7	-0.050	-0.048	7.1596	0.412
8	-0.002	0.004	7.1627	0.519

	AC	PAC	Q-Stat	Prob
1	0.010	0.010	0.0947	0.758
2	-0.025	-0.026	0.7172	0.699
3	-0.013	-0.012	0.8794	0.830
4	0.005	0.004	0.8991	0.925
5	0.032	0.031	1.8654	0.867
6	-0.007	-0.008	1.9138	0.927
7	-0.050	-0.048	4.2743	0.748
8	-0.002	-0.001	4.2798	0.831

Tab. 4.24 Korelogram reziduí lineárního a nelineárního modelu volatility časové řady *PX_2*

	AC	PAC	Q-Stat	Prob
1	0.052	0.052	2.5877	0.108
2	-0.008	-0.011	2.6510	0.266
3	0.011	0.012	2.7634	0.430
4	0.065	0.064	6.8094	0.146
5	-0.002	-0.009	6.8148	0.235
6	-0.062	-0.061	10.532	0.104
7	-0.026	-0.021	11.191	0.130
8	0.066	0.064	15.358	0.053

	AC	PAC	Q-Stat	Prob
1	0.010	0.010	0.0983	0.754
2	-0.021	-0.021	0.5117	0.774
3	0.013	0.013	0.6746	0.879
4	0.071	0.071	5.5892	0.232
5	0.009	0.009	5.6743	0.339
6	-0.048	-0.046	7.9336	0.243
7	-0.039	-0.040	9.3781	0.227
8	0.063	0.057	13.163	0.106

V Tab. 4.23 vlevo je zobrazen korelogram lineárního modelu GARCH(1,2) a vpravo korelogram nelineárního modelu EGARCH-M(1,1). V Tab. 4.24 vlevo je znázorněn korelogram lineárního modelu *IGARCH (1,1)* a vpravo korelogram nelineárního modelu *EGARCH(1,2)*. Z Tab. 4.23 a 4.24 lze tedy vyvodit, že u žádného posuzovaného modelu volatility časové řady *PX_1* a *PX_2* se nevyskytuje autokorelace.

Na základě provedeného testu na přítomnost autokorelace u nejlepších lineárních a nelineárních modelů za první i druhé období, bylo zjištěno, že se u těchto modelů autokorelace nevyskytuje. Tento závěr pak znamená, že časové řady reziduí nejsou závislé na svých zpožděných časových řadách reziduí.

4.6.3 Test heteroskedasticity

Test heteroskedasticity již byl v této práci jednou proveden, viz kapitola 4.4, avšak v tomto případě je tento test důležité provést pro diagnostiku odhadů modelu z kapitoly 4.6. I v tomto případě bude heteroskedasticita testována pomocí ARCH-LM testu, viz kapitola 3.7. Závěry tohoto testu by však měly být odlišné od závěrů z kapitoly 4.4, ve které časové řady byly heteroskedastické, avšak odhadem modelu by měla být heteroskedasticita odstraněna a modely by měly být homoskedastické. Pracovat budeme opět se zpožděním o 1, 2, 3 a 4 dny.

Tab. 4.25 ARCH – LM test reziduí nejlepších odhadů modelu volatility pro BUX_1 a BUX_2

	BUX_1		BUX_2	
	GARCH(1,1)	EGARCH(1,1)	GARCH(1,1)	EGARCH(1,1)
RESID^2(-1)	-0,583898	-0,331905	0,048640	1,242199
Prob.	0,5594	0,7400	0,9612	0,2145
RESID^2(-2)	-0,474105	-0,425737	1,856910	2,623051
Prob.	0,6355	0,6704	0,0636	0,0589
RESID^2(-3)	1,081295	1,630964	-0,035994	0,513857
Prob.	0,2798	0,1032	0,9713	0,6075
RESID^2(-4)	0,576865	0,398589	-0,741559	-1,158196
Prob.	0,5642	0,6903	0,4585	0,2471

Z Tab. 4.25 vyplývá, že v případě odhadů modelu GARCH(1,1) a EGARCH(1,1) za první období nedochází k zamítnutí nulové hypotézy o homoskedasticitě, což tedy znamená, že rozptyl reziduí těchto modelů je konstantní. Výsledek testu heteroskedasticity ve druhém období je stejný jako v období prvním, i zde je u obou zkoumaných modelů potvrzena homoskedasticita.

Tab. 4.26 ARCH – LM test reziduí nejlepších odhadů modelu volatility pro WIG_1 a WIG_2

	WIG_1		WIG_2	
	IGARCH(1,2)	EGARCH(0,1)	IGARCH(1,2)	EGARCH(2,1)
RESID^2(-1)	-1,399374	-0,515618	-1,902577	0,676836
Prob.	0,1620	0,6062	0,0574	0,4987
RESID^2(-2)	-0,443537	0,514819	-0,688451	-1,550918
Prob.	0,6575	0,6068	0,4913	0,1213
RESID^2(-3)	-0,253521	1,364573	1,338959	0,793867
Prob.	0,7999	0,1727	0,1809	0,4275
RESID^2(-4)	0,738904	4,297914	3,037986	1,053997
Prob.	0,4601	0,0000*	0,0024*	0,2922

Z Tab. 4.26 je patrné, že zpožděné čtverce reziduí nejsou statisticky významné u modelu IGARCH(1,2) za první období a EGARCH(2,1) za druhé období, je zde tedy potvrzena homoskedasticita. Naopak model EGARCH(0,1) za první období a IGARCH(1,2) za druhé období vykazuje statisticky významné čtverce reziduí u zpoždění o 4 dny. V tomto případě je tedy hypotéza o homoskedasticitě zamítnuta a rozptyl reziduí u těchto modelů není konstantní. Heteroskedasticita u těchto modelů je pravděpodobně způsobená vynecháním podstatné vysvětlující proměnné v rovnici podmíněného rozptylu, avšak je třeba brát v úvahu, že statisticky významné je až 4 zpoždění.

Tab. 4.27 ARCH – LM test reziduí nejlepších odhadů modelu volatility pro SAX_1 a SAX_2

	SAX_1		SAX_2	
	IGARCH(2,2)	EGARCH-M(0,1)	IGARCH-M(2,2)	EGARCH-M(1,2)
RESID^2(-1)	-0,441942	0,124756	0,154387	0,240894
Prob.	0,6586	0,9007	0,8773	0,8097
RESID^2(-2)	-0,105176	1,535620	0,038569	-0,402635
Prob.	0,9163	0,1250	0,9692	0,6873
RESID^2(-3)	0,861672	3,149742	0,195931	0,003122
Prob.	0,3891	0,0622	0,8447	0,9975
RESID^2(-4)	-0,820020	0,600092	-0,390126	-0,150955
Prob.	0,4124	0,5486	0,6965	0,8800

V Tab. 4.27 je vidět, že všechny modely jsou statisticky nevýznamné a je u nich tedy zamítnuta hypotéza o heteroskedasticitě. Rezidua modelů jsou homoskedastická a jejich rozptyl je konstantní.

Tab. 4.28 *ARCH – LM test reziduí nejlepších odhadů modelu volatility pro PX_1 a PX_2*

	PX_1		PX_2	
	GARCH(1,2)	EGARCH-M(1,1)	IGARCH(1,1)	EGARCH(1,2)
RESID^2(-1)	-0,655527	-1,389471	-0,748885	-0,127963
Prob.	0,5123	0,1650	0,4541	0,8982
RESID^2(-2)	0,357308	0,258838	0,413263	0,519770
Prob.	0,7209	0,7958	0,6795	0,6033
RESID^2(-3)	-0,569467	-0,712256	0,527602	-0,506458
Prob.	0,5692	0,4765	0,5979	0,6127
RESID^2(-4)	-0,656777	-0,304774	0,179516	0,763440
Prob.	0,5115	0,7606	0,8576	0,4454

Z Tab. 4.28 je patrné, že zpožděné čtverce reziduí u všech čtyř modelů nejsou statisticky významné, tedy u všech těchto odhadů modelů volatility přijímáme hypotézu o homoskedasticitě, tedy konstantním rozptylu.


Z provedeného testu heteroskedasticity vyplývá, že testované lineární a nelineární modely volatility přijaly ve všech případech kromě dvou modelů hypotézu o homoskedasticitě. Homoskedasticita pak znamená, že rezidua modelů mají konstantní rozptyl. U modelů EGARCH(0,1) časové řady WIG_1 a IGARCH(1,2) časové řadu WIG_2 nastal případ, kdy byla zjištěna statistická významnost u čtvrtého zpoždění čtverců reziduí. Z tohoto důvodu byla u těchto modelů přijata hypotéza o heteroskedasticitě způsobené pravděpodobně vynecháním podstatné vysvětlující proměnné z rovnice podmíněného rozptylu.

4.7 Grafické vyjádření volatility

V této podkapitole bude vyjádřen vývoj volatility u všech čtyř zkoumaných burzovních indexů za první i druhé období včetně dělení na lineární a nelineární modely. Volatilita bude v grafu vyjádřena v podobě podmíněného rozptylu. Při interpretaci výkyvů ve volatilitě vycházíme z údajů na webových stránkách společnosti ING Investment Management C.R., a.s., kde je uveden přehled nejvýznamnějších událostí nejen z pohledu celosvětového, ale také v jednotlivých ekonomikách včetně těch středoevropských.


a) Maďarsko

Obrázek 4.11 Vývoj volatility na základě lineárního a nelineárního modelu za 1. období



Z obrázku 4.11 je vidět významné zvýšení volatility v období kolem dubna 2005, kdy došlo ke globálnímu výběru zisků na akciových trzích, které tímto začaly stagnovat (a). V období října a listopadu došlo k zvýšení volatility pravděpodobně z důvodu vzniku obav o vývoji platební bilance v Maďarsku (b). Kolem května 2006 došlo opět k razantnímu zvýšení volatility, a to z důvodu razantních propadů na akciových trzích střední Evropy způsobené globální korekcí akciových trhů (c).

Obrázek 4.12 Vývoj volatility na základě lineárního a nelineárního modelu za 2. období




Z obrázku 4.12 v případě lineárního i nelineárního modelu je patrný vysoký skok volatility za období od srpna 2008 do prosince 2008. V tomto období existuje špatná nálada na trhu, která kulminuje zejména krachem americké banky Lehman Brothers a vydáním zprávy o zaměstnanosti v USA. Pád cen akcií, u kterých nebylo možné určit, kdy přijde dno, způsobil velké emoce na trhu, které se přenášely do růstu volatility. Emoce vyvrcholily 23. a 24. října,

kdy před 80 lety v této době došlo ke krachu newyorské burzy, a z tohoto důvodu byla v tyto dny volatilita v maximech (a).


b) Polsko

Obrázek 4.13 *Vývoj volatility na základě lineárního a nelineárního modelu za 1. období*



Z obrázku 4.13 jsou patrné, dva nejvyšší skoky ve volatilitě ke konci období. První velký skok je v období kolem května 2006 roku, kdy byly zaznamenány razantní propady na akciových trzích střední Evropy způsobené globální korekcí na akciových trzích, kterou nastartovala obava z inflačních tlaků. Nejistota na trzích a propad hodnoty akcií provázela tedy i zvýšená volatilita (a). Druhý velký skok zaznamenala volatilita přibližně kolem srpna 2007, jenž byl způsoben pravděpodobně očekáváním ohledně zvýšení sazeb v Eurozóně a problémy hypoték v USA. Investoři se bojí projevu v reálné ekonomice a přesouvají svou pozornost z akcií na bezrizikové investice (b).


Obrázek 4.14 *Vývoj volatility na základě lineárního a nelineárního modelu za 2. období*



Z obrázku 4.14 lze pozorovat největší skok volatility v období od srpna 2008 do prosince 2008, který je spojen se špatnou náladou na trhu, viz druhé období indexu BUX (a).


c) Slovensko

Obrázek 4.15 Vývoj volatility na základě lineárního a nelineárního modelu za 1. období



Při zkoumání vývoje volatility budeme vycházet spíše z lineárního modelu, který je mnohem bohatší na výkyvy ve volatilitě. Z obrázku 4.15 vidíme, že obdobím s vysokou volatilitou je březen až květen roku 2005, které způsobil pravděpodobně březnový výběr zisků, kdy globální akciové trhy zůstaly na původních hodnotách (a). V prosinci 2005 došlo k dalšímu razantnímu zvýšení volatility pravděpodobně z důvodu zvýšené nervozity finančních trhů před volbami a výsledku voleb na Slovensku (b).

Obrázek 4.16 Vývoj volatility na základě lineárního a nelineárního modelu za 2. období




Jak vidíme z obrázku 4.16 tak průběh volatility lépe vystihuje nelineární model oproti modelu lineárnímu. Zhruba v listopadu 2008 vidíme kulminaci zvyšování volatility způsobenou prohlubující se globální finanční krizí a obavami z nepříznivého makroekonomického vývoje hlavních ekonomik, zejména pak USA. V této době se očekává prudší ekonomické zpomalení,

než se očekávalo (a). Zvýšení volatility v tomto období přišlo ve srovnání s ostatními zeměmi o měsíc později, avšak volatilita rostla ještě dále v dalších obdobích.

Prvním tímto obdobím, kde je výše volatility nejvyšší, byl březen 2009, který byl ve znamení propadu akciových trhů na historická minima, a to v důsledku nepříznivých makroekonomických zpráv. Další negativní faktory přicházely z bankovního sektoru, kde narůstaly obavy o zdraví finančních institucí (b). V červnu 2009 došlo opět ke zvýšení volatility způsobené vybíráním zisků a k nepříznivým makroekonomickým datům. Investoři se rozhodli spíše přistoupit k částečné realizaci svých zisků a akciové indexy ztratily většinu svých zisků (c).


d) Česká republika

Obrázek 4.17 Vývoj volatility na základě lineárního a nelineárního modelu za 1. období



Vývoj volatility u lineárního a nelineární modelu je téměř totožný. Na obrázku 4.17 je vidět 2 nejvyšší skoky ve volatilitě. První z nich je v březnu 2005, kdy došlo k vybírání zisků a zastavení výběru výnosů zahraničními investory. Pokles může být spojen i s politickou situací v ČR a možností pádu vlády při odstoupení premiéra (a). Dalším významným momentem je červen 2006, kdy kulminoval razantní pokles akcií způsobený volbami do Poslanecké sněmovny ČR a způsobil špatnou náladu na trhu (b).

Obrázek 4.18 *Vývoj volatility na základě lineárního a nelineárního modelu za 2. období*



Z obrázku 4.18 v případě lineárního i nelineárního modelu je opět patrný vysoký skok volatility za období od srpna 2008 do prosince 2008 (a). Interpretace vysoké volatility v tomto období je stejná jako u indexu BUX za druhé období. Z obrázku je rovněž patrné, že vývoj volatility u indexu PX je velmi podobný indexu BUX.

5 Shrnutí výsledků

Čtvrtá kapitola předložené diplomové práce byla věnována empirické analýze volatility vybraných akciových indexů. V úvodní části byly charakterizovány vybrané akciové trhy zemí střední Evropy se zaměřením na jejich hlavní akciové indexy. Dále byla zdůvodněna volba denních dat a bylo vymezeno testovací období, které začíná 1. května 2004 a končí 31. prosince 2009. V tomto období byla pak vytyčena dva dílčí časová období v délce tří a půl roku, přičemž se tato období klouzavě posunují o jeden a půl roku.

Vybrané akciové trhy reprezentují indexy BUX, WIG, SAX a PX, u kterých jsme dále sledovali chování logaritmů denních výnosů těchto indexů. Toto sledování bylo provedeno pomocí základní popisné analýzy logaritmů denních výnosů, ze kterých bylo možné charakterizovat vybrané časové řady. Z popisných charakteristik uvedených v Tab. 4.4 a 4.5 a provedeného Jarque-Bera testu, viz Tab. 4.6 je možné konstatovat, že u všech zkoumaných časových řad indexů BUX, WIG, SAX a PX nebyl naplněn předpoklad normality. Logaritmy denních výnosů těchto indexů, tedy nejsou normálně rozdělena, ale tomuto rozdělení se blíží.

V další části byl proveden test stacionarity výnosů, viz kapitola 4.3, a to pomocí rozšířeného Dickey-Fullerova testu jednotkovosti kořene. Z výsledků tohoto testu, viz Tab. 4.7 je možné konstatovat, že u všech testovaných časových řad byla přijata hypotéza stacionarity výnosů na hladině významnosti 1%, 5% a 10%.

Stěžejní částí čtvrté kapitoly byl odhad nejlepšího lineárního a nelineárního modelu pro jednotlivé časové řady logaritmů denních výnosů za první a druhé období za účelem. Regresní model byl pak tvořen vždy zkoumanou časovou řadou jako vysvětlovanou proměnnou a konstantou jako vysvětlující proměnnou. V případě, že v modelu byla přítomná autokorelace, byla do modelu přidána další vysvětlující proměnná v podobě zkoumané časové řady zpožděné o jedno období. Přehled nejlepších výsledných odhadů lineárních a nelineárních modelů volatility pro jednotlivé časové řady je možné nalézt v Tab. 5.1 a 5.2. V těchto tabulkách jsou rovněž výsledky provedených diagnostických testů normality, autokorelace a heteroskedasticity.

Tab. 5.1 *Výsledky diagnostických testů provedených u lineárních modelů volatility*

	Lineární model	Normalita	Autokorelace	Heteroskedasticita
BUX_1	GARCH(1,1)	NE	NE	NE
WIG_1	IGARCH(1,2)	NE	NE	NE
SAX_1	IGARCH(2,2)	NE	NE	NE
PX_1	GARCH(1,2)	NE	NE	NE
BUX_2	GARCH(1,1)	NE	NE	NE
WIG_2	IGARCH(1,2)	NE	NE	ANO
SAX_2	IGARCH-M(2,2)	NE	NE	NE
PX_2	IGARCH(1,1)	NE	NE	NE

Tab. 5.2 *Výsledky diagnostických testů provedených u nelineárních modelů volatility*

	Nelineární model	Normalita	Autokorelace	Heteroskedasticita
BUX_1	EGARCH(1,1)	NE	NE	NE
WIG_1	EGARCH(0,1)	NE	NE	ANO
SAX_1	EGARCH-M(0,1)	NE	NE	NE
PX_1	EGARCH-M(1,1)	NE	NE	NE
BUX_2	EGARCH(1,1)	NE	NE	NE
WIG_2	EGARCH(2,1)	NE	NE	NE
SAX_2	EGARCH-M(1,2)	NE	NE	NE
PX_2	EGARCH(1,2)	NE	NE	NE

Z Tab. 5.1 a 5.2 je patrné, že volatilitu denních výnosů indexu BUX lze nejlépe modelovat pomocí lineárního modelu GARCH(1,2), který je v prvním i druhém období nejlepším lineárním modelem. Z hlediska nelineárních modelů byl nejlepším modelem v obou dvou obdobích EGARCH(1,1).

Co se týká vývoje volatility denních výnosů indexu WIG, tu nejlépe zobrazuje lineární model IGARCH(1,2), který je nejlepším lineárním modelem za první i druhé období. U nelineárních

modelů byl pak nejlepší model EGARCH(0,1) za první období a EGARCH(2,1) za druhé období.

Průběh volatility denních výnosů indexu SAX pak nejlépe zobrazují lineární modely IGARCH, kdy v prvním období byl nejlepší IGARCH(2,2) a ve druhém IGARCH-M(2,2). Z nelineárních modelů pak byl nejlepší model EGARCH-M(0,1) za první období a EGARCH-M(1,2) za období druhé.

Doposud byly nejlepší modely za první i druhé období vždy stejného typu, avšak v případě indexu PX je tomu jinak. V prvním období nejlépe vývoj volatility zobrazoval lineární model GARCH(1,2), ve druhém období pak IGARCH(1,1). Rozdíl mezi těmito modely je zejména v restriktivní podmínce modelu IGARCH, viz kapitola 3.4.3, která je charakteristická pro finanční časové řady. Z nelineárních modelů byl pak nejlepším modelem za první období EGARCH-M(1,1) a za období druhé EGARCH(1,2).

Z předložených výsledků vyplývá podobnost ve vývoji volatility indexů WIG a SAX na jedné straně, a podobnost vývoje indexů BUX a PX na straně druhé.

Po odhadu modelů volatility bylo nutné u těchto modelů provést test normality, pro který byl opět použit Jarque-Bera test. Z Tab. 5.1 a 5.2 je vidět, že u všech lineárních a nelineárních modelů nebyla přijata hypotéza o normálním rozdělení pravděpodobnosti, viz kapitola 4.6.1.

Dalším provedeným testem byl test autokorelace, tedy zkoumání zda je přítomná sériová závislost reziduální složky. Test byl proveden na základě korelogramu, a jak je patrné z Tab. 5.1 a 5.2 tak autokorelace nebyla potvrzena u žádného lineárního a nelineárního modelu volatility. To pak znamená, že časové řady reziduí nejsou závislé na svých zpožděných časových řadách reziduí. Korelogramy včetně popisů jsou k nalezení v kapitole 4.6.2.

Posledním diagnostickým testem provedeným na odhadnutých modelech je test heteroskedasticity, jenž byl proveden v kapitole 4.6.3. Pro tyto účely byl použit ARCH-LM test. Z Tab. 5.1 je pak patrné, že u lineárních modelů za první období byla ve všech případech hypotéza o heteroskedasticitě zamítnutá a přijata hypotéza o homoskedasticitě. Tedy u těchto modelů je potvrzen konstantní rozptyl. U lineárních modelů druhého období, pak v případě modelu IGARCH(1,2) indexu WIG byla hypotéza o heteroskedasticitě přijata, což znamená, že rezidua tohoto modelu nemají konstantní rozptyl. Důvodem je pravděpodobně nezahrnutí podstatné vysvětlující proměnné do rovnice podmíněného rozptylu, avšak je třeba brát v úvahu i fakt, že heteroskedasticita byla potvrzena až u zpoždění o 4 období.

V Tab. 5.2 lze pak najít výsledky testu heteroskedasticity u nelineárních modelů. V prvním období je opět vidět, že model EGARCH(0,1) indexu WIG opět vykazuje heteroskedasticitu způsobenou zřejmě nezahrnutím důležité proměnné do rovnice podmíněného rozptylu. U ostatních modelů prvního období a všech modelů druhého období byla přijata hypotéza o homoskedasticitě, tedy konstantním rozptylu.

Proběhlo rovněž testování asymetrie příchodu nových informací u nelineárních modelů, jelikož v případě lineárních modelů není asymetrie zohledněna. Pod pojmem asymetrie příchodu nových informací je myšleno, jak nové pozitivní či negativní informace ovlivňují výši volatility, neboli jak se do ní promítají kladné a záporné šoky. V obou zkoumaných obdobích byly nejlepšími modely variance EGARCH, u kterých byl ve všech modelech parametr asymetrie statisticky významný s výjimkou modelu EGARCH-M(0,1) indexu SAX a modelu EGARCH(0,1) indexu WIG, kde tento parametr nebyl součástí modelu. Pro grafické zobrazení toho jak se nová informace promítá do volatility, by bylo možné použít křivku dopadu novinek. Potvrdila se tedy hypotéza, že kladné a záporné šoky ovlivňují volatilitu různým způsobem a větší dopad na volatilitu mají negativní zprávy.

Jelikož z výsledných odhadů modelů bylo několik typu ARCH-M, tedy výnos v hlavní rovnici je závislý na podmíněném rozptylu, budeme se věnovat také hodnocení těchto modelů. U lineárních modelů byl ve druhém období použit model IGARCH-M(2,2) pro index SAX. Použití tohoto modelu naznačuje skutečnost, že úroveň variability a výnosů na sobě závisí a model ARCH-M naznačuje jejich vztah. Stejný případ nastal u nelineárních modelů prvního období, a to konkrétně modelu EGARCH-M(0,1) indexu SAX a EGARCH-M(1,1) indexu PX. V druhém období byla variance statisticky významná v hlavní rovnici u nelineárního modelu EGARCH-M(1,2) indexu SAX.

Obecně lze tedy říci, že jelikož byl koeficient podmíněné směrodatné odchylky modelů prvního období EGARCH-M(0,1) indexu SAX a EGARCH-M(1,1) indexu PX kladný a statisticky významný. U těchto modelů byl na základě výsledků potvrzen předpoklad ocenění rizika na trhu. U ostatních dvou ARCH-M modelů indexu SAX za druhé období byl koeficient podmíněné směrodatné odchylky rovněž statisticky významný a kladný, což tedy znamená, že opět s růstem volatility roste výnos.

V závěru kapitoly byl na základě grafického vyjádření volatility v podobě podmíněného rozptylu charakterizován vývoj a stabilita volatility u konkrétních modelů. U největších výkyvů volatility dle jejího grafického vyjádření, viz kapitola 4.7, byly popsány pravděpodobné příčiny těchto výkyvů způsobujících vysokou volatilitu.

Ze srovnání mezi prvním a druhým zkoumaným obdobím je patrné, že ve druhém období tedy od 1. 5. 2006 do 31. 12. 2009, byl skok ve volatilitě způsobený vyvrcholením světové finanční krize mnohem vyšší než v případě nejvyšších skoků volatility za první období, tedy od 1. 5. 2004 do 31. 12. 2007. Průběh volatility mezi jednotlivými zeměmi byl velmi podobný zejména v případě prvního období. Ve druhém období byly již větší rozdíly, kdy volatilita indexu BUX a PX se vyvíjela velmi podobně. Volatilita indexu WIG a SAX byla rovněž velmi podobná, avšak ve srovnání s vývojem volatility indexu BUX a PX byla mnohem variabilnější a vyšší.

6 Závěr

Jedním z nejdůležitějších faktorů ovlivňující rozhodování a chování ekonomických subjektů je riziko. Zaměříme-li se pak na finanční trhy, pak riziko hraje významnou roli při rozhodování investorů. Obecně se dá říci, že čím vyšší je riziko, jež jsou ekonomické subjekty ochotny podstoupit, tím větší by měl být výnos, který za podstoupení rizika obdrží. Je třeba však počítat i s případnou ztrátou. Jelikož investoři jsou stejní jako obyčejní lidé, někteří riziko vyhledávají, jiní jsou naopak rizikově averzní, pak své chování musí přizpůsobovat riziku, jež z tohoto chování vyplývá. Na finančních trzích je riziko vyjádřeno v podobě volatility.

A právě volatilita byla předmětem zkoumání předložené diplomové práce. Hlavním cílem předložené diplomové práce byla empirická analýza volatility vybraných akciových indexů zemí střední Evropy v období od roku 2004 do roku 2009 pomocí lineárních a nelineárních metod. Z cíle diplomové práce tedy vyplývá, že práce byla zaměřena na specifickou část finančního trhu, tedy na středoevropský akciový trh. Jako reprezentanty těchto trhů byly zvoleny akciové indexy. Konkrétními zkoumanými indexy tedy byl BUX, WIG, SAX a PX, reprezentující maďarský, polský, slovenský a český akciový trh. Cíl práce byl pak realizován pomocí lineárních nebo nelineárních modelů podmíněné heteroskedasticity, u kterých byla použita denní frekvence dat ve dvou vymezených časových obdobích od května 2004 do prosince 2009.

Předložená diplomová práce byla zaměřena na analýzu volatility, včetně posouzení vhodnosti využití lineárních a nelineárních modelů, analýzy stability výsledků v čase, testování asymetrie příchodu nových informací na trh a testování zda trh oceňuje riziko. Práce byla rozdělena do šesti kapitol, a to kapitoly úvodní a závěrečné.

V teoreticko-metodologické části byla uvedena charakteristika finančních časových řad se zaměřením na normalitu, linearitu a stacionaritu časových řad. Kapitola druhá byla věnována vlivu mikrostruktury trhu, problému manipulace kursů, volbě a transformace dat. Třetí kapitola byla zaměřena na lineární a nelineární metody modelování volatility. Důraz byl kladen na komplexní průběh výstavby modelu volatility od testování stacionarity až po diagnostické testy a predikci. Byl zde rovněž popsán a vymezen metodologický aparát a postup, jenž se v dané problematice aplikuje včetně vymezení ekonometrických modelů volatility, statistických testů a jejich předpokladů.

V části aplikačně-ověřovací byla uvedena základní charakterizace maďarského, polského, slovenského a českého akciového trhu, jakožto objektů zkoumání této práce s důrazem na akciové indexy, které lze považovat za jejich reprezentanty. Zvolená data byla rozdělena do dvou testovacích období, tedy od 1. 5. 2004 do 31. 12. 2007 a od 1. 5. 2006 do 31. 12. 2009. U zvolených dat v podobě logaritmů denních výnosů byla provedena základní statistická analýza, test stacionarity výnosů a test heteroskedasticity. V další části byly odhadnuty nejlepší lineární a nelineární modely volatility, u kterých byly dále provedeny testy normality, autokorelace, heteroskedasticity. V závěru čtvrté kapitoly pak byl průběh volatility graficky vyjádřen a u největších skoků ve volatilitě popsán pravděpodobný důvod jejich vzniku. Souhrnný přehled výsledů empirické analýzy volatility včetně výsledků statistických testů a ekonometrických modelů byl popsán v kapitole 5.

Hlavním cíle této části bylo odhadnout modely, které budou nejlépe popisovat průběh volatility jednotlivých indexů za první a druhé sledované období. Nejlepší výsledné odhady lineárních a nelineárních modelů volatility pro jednotlivé časové řady je možné nalézt v Tab. 5.1 a 5.2. Tabulky obsahují rovněž výsledky diagnostických testů.

Na základě testu normality reziduální složky bylo zjištěno, že se v žádném ze zkoumaných případů nevyskytuje normalita, tedy rezidua těchto modelů nejsou normálně rozdělena. Z testu autokorelace pak vyplývá, že u žádného modelu se nevyskytuje sériová závislost reziduální složky, tedy autokorelace není přítomná v těchto modelech.

Co se týče testu heteroskedasticity reziduální složky, tak ve většině případů zde byla přijata hypotéza o homoskedasticitě tedy konstantním rozptylu. Výjimkou byly dva modely indexu WIG, kde důvodem výskytu heteroskedasticity byla statistická významnost u čtvrtého zpoždění reziduí. Model podmíněného rozptylu byl tedy špatně specifikován a v rovnici podmíněného rozptylu nebyla zahrnuta klíčová významná proměnná.

Hodnoty indexu determinace byly u všech modelů velmi nízké, z čehož vyplývá, že se je nedoporučuje využívat pro predikční účely. Zjištění a získání hodnot vysvětlujících proměnných by tedy bylo jednak velmi časově náročné a jednak v některých případech nemožné, jelikož se tyto proměnné nevyskytují v denní frekvenci. Všechny závěry vycházející z aplikační části této diplomové práce jsou v souladu s ekonomickou teorií.

Z grafického vyjádření vývoje volatility a jejího popisu jsme schopni určit pravděpodobné faktory, jež vedly k zvyšování volatility. Ze srovnání mezi prvním a druhým obdobím je rovněž patrné, že ve druhém období byl šok způsobený vyvrcholením světové finanční krize

mnohem větší, než ve srovnání s ostatními šoky druhého období a také šoky za první období. Volatilita se v případě jednotlivých zemí vyvíjela velice podobně, patrná je podoba u indexů BUX a PX, u kterých byly viditelné šoky menší než v případě indexů WIG a SAX.

Jak již bylo zmíněno, volatilita je důležitá ve finanční praxi zejména pro investory, jelikož ovlivňuje výši pravděpodobných budoucích výnosů. Investoři se tedy na základě výše volatility a jejího vývoje rozhodují, zda investici provést či nikoliv. Důležitou roli přitom hraje i to, jaký vztah má investor k riziku.

Jelikož byly v úvodní části této diplomové práce stanoveny i dílčí cíle práce, je nutné tyto cíle dále zhodnotit.

DÍLČÍ CÍL 1 – Posouzení vhodnosti využití lineárních a nelineárních modelů volatility.

Na základě provedených odhadů lineárních a nelineárních modelů volatility bylo zjištěno, že jak lineární, tak nelineární modely volatility splňují podmínky na ně kladené a je možné je použít pro modelování volatility a jejího vývoje. Z hlediska výsledků informačních kritérií měla většina lineárních modelů volatility za první období lepší výsledky než modely nelineární. Ve druhém období měla naopak většina nelineárních modelů volatility lepší výsledky těchto kritérií než v případě modelů lineárních. Z toho vyplývá, že použití lineárních modelů volatility bude vhodnější pro první období, naopak pro druhé období bude příhodnější použít nelineární modely volatility.

DÍLČÍ CÍL 2 – Analýza stability výsledků ve vymezených časových obdobích.

Co se týče analýzy stability, pak v případě modelů indexu BUX byly v prvním i druhém období použity stejné lineární a nelineární modely volatility. V případě indexu WIG je situace podobná, jelikož lineární a nelineární modely za první a druhé období jsou shodného typu. U indexu SAX jsou modely opět stejného typu, avšak u lineárního modelu za první období se nepracuje s modelem typu ARCH-M jako u ostatních. Lineární modely volatility indexu PX byly odlišné v 1. a 2. období. Z hlediska nelineárních modelů byl nejlepším odhadem za 1. a 2. období u indexu PX stejný typ modelu, avšak s tím rozdílem, že v prvním období se jednalo o model typu ARCH-M.

DÍLČÍ CÍL 3 – Testování asymetrie příchodu nových informací na trh.

Ve všech zkoumaných modelech s výjimkou EGARCH-M(0,1) modelu u indexu SAX a EGARCH(0,1) modelu u indexu WIG byl parametr asymetrie příchodu nových informací statisticky významný, a tedy se jsou v těchto modelech ovlivňovány kladné a záporné šoky

novými informacemi. Pro zjištění toho jak se tyto nové informace promítají do volatility, by bylo nutné zkonstruovat křivku dopadu novinek, což z důvodu rozsáhlosti této práce provedeno nebude.

DÍLČÍ CÍL 4 – Testování zda trh oceňuje riziko.

Bylo provedeno testování předpokladu, že trh oceňuje riziko. V případě modelu IGARCH-M(2,2) u indexu SAX a modelu EGARCH-M(1,2) u indexu SAX byla hodnota koeficientu podmíněné směrodatné odchylky záporná a statisticky významná. Z tohoto důvodu nebyla u těchto modelů potvrzena silná averze k riziku, jak tomu bylo u modelů EGARCH-M(0,1) indexu SAX a EGARCH-M(1,1) indexu PX.

V této práci byly použity časové řady o denní frekvenci. Problémem těchto řad je však skutečnost, že pracujeme s uzavíracími kursy. Tyto kursy nám však neumožňují získat hlubší pochopení složitých dynamických procesů, jakým je formování tržních trendů. Problematika předložené diplomové práce by mohla být rozvinuta využitím intradenních dat, což by rozšířilo nejen počet pozorování, ale zvýšilo přesnost ve vývoji volatility. Dalšími možnostmi rozšíření předložené diplomové práce by byla konstrukce křivky dopadu novinek, predikce volatility, a případně komplikovanější specifikace modelů volatility, zejména pak nelineárních modelů.

Za hlavní přínosy předložené diplomové práce lze v oblasti teorie považovat přehledné zmapování modelování volatility pomocí lineárních a nelineárních modelů volatility. Z hlediska praxe je možné považovat za přínosné především využití výsledků této práce pro modelování volatility výnosů akciových indexů zkoumaných zemí, jelikož z práce vyplývají závěry o jejich charakteristikách a modelech, jež jsou pro jejich odhad neoptimálnější. Důležitým přínosem z hlediska praxe je rovněž analýza vývoje volatility v čase a možnost na základě odhadnutých modelů volatilitu predikovat. Předložená diplomová práce přináší přínosy také pro pedagogickou činnost, kdy výsledky práce mohou být využity v rámci pedagogické činnosti na ekonomických fakultách, zejména pro studenty v oboru Finance.

Seznam použité literatury

- ARLT, J. *Moderní metody modelování ekonomických časových řad*. 1. vyd. Praha: Grada Publishing, 1999, 312 s. ISBN 80-7169-539-4.
- ARLT, J.; ARLTOVÁ, M. *Finanční časové řady*. 1. vyd. Praha: Grada Publishing, 2003, 220 s. ISBN 80-247-0330-0.
- BACHELIER, L. *The random Character of Stock Market Prices*. Cambridge: Massachusetts Institute of Technology Press, 1964.
- BAILLIE, R. T.; BOLLERSLEV, T.; MIKKELSEN, H. O. Fractionally Integrated Autoregressive Conditional Heteroskedasticity. *Journal of Econometrics* 74, 1996, s. 3-30.
- BLACK, F. The Pricing of Commodity Contracts. *Journal of Financial Economics* 3, 1976, s. 167-179.
- BOLLERSLEV, T. Generalized Autoregressive Conditional Heteroskedasticity. *Journal of Econometrics* 31, 1986, s. 307-327.
- BOLLERSLEV, T.; WOOLDRIDGE, J. M. Quasi-Maximum Likelihood Estimation and Inference in Dynamic Models with Time-Varying Covariances. *Econometric Reviews* 11, 1992, s. 143-172.
- CAMPBELL, J. Y.; LO, A. W.; MACKINLAY, A. C. *The Econometrics of Financial Markets*. 2nd Ed. New York: Princeton University Press, 1997. 632 s. ISBN 0-691-04301-9
- CIPRA, T. *Finanční ekonometrie*. 1. vyd. Praha: Ekopress, 2008. 538 s. ISBN 9788086929439.
- COWLES, A. Can Stock Market Forecasters Forecast? *Econometrica* 1, 1933. s. 309-324.
- DICKEY, D. A.; FULLER, W. A. Distribution of the Estimators for Autoregressive Time Series with a Unit Root. *Journal of the American Stat. Association* 74, 1979, s. 427-431.
- ENGLE, R. F. Autoregressive Conditional Heteroskedasticity with Estimates of the Variance of United Kingdom Inflation. *Econometrica* 50, 1982, s. 987-1007.
- ENGLE, R. F.; BOLLERSLEV, T. Modelling the Persistence of Conditional Variances. *Econometric Reviews* 5, 1986, s. 1-50.
- ENGLE, R. F.; LILIEN, D. M.; ROBINS, R. P. Estimating Time Varying Risk Premia in the Term Structure: the ARCH-M Model. *Econometrica* 55, 1987, s. 391-407.
- ENGLE, R. F.; NG, V. K. Measuring and Testing the Impact of News on Volatility. *Journal of Finance* 48, 1993, s. 1749-1778.
- FAMA, E. F. The Behavior of Stock Market Prices. *Journal of Business* 38, 1965, s. 34-105.

- FRANCES, P. H.; van DIJK, D. *Non-linear Time Series Models in Empirical Finance*. Cambridge: Cambridge University Press, 2000.
- GLOSTEN, L. R.; JAGANNATHAN, R.; RUNKLE, D. E. On the Relation between the Expected Value and the Volatility of the Nominal Excess Return on Stock. *Journal of Finance* 48, 1993, s. 1779-1801.
- ING INVESTMENT MANAGEMENT Zprávy z finančních trhů. *ING Fondy* [online]. [cit. 2010-03-22] Dostupný z WWW: <<http://www.ingfondy.cz/news.asp?page=40>>.
- KWIATKOWSKI, D.; PHILLIPS, P. C. B.; SCHMIDT, P.; SHIN, Y. Testing the Null Hypothesis of Stationarity Against the Alternative of a Unit Root. *Journal of Econometrics* 54, 1992, s. 159-178.
- LEE, J. H. H. A Lagrange Multiplier Test for GARCH Models. *Economics Letters* 37, 1991, s. 265-271.
- LEE, S. W.; HANSEN, B. E. Asymptotic Theory for the GARCH(1,1) Quasi-Maximum Likelihood Estimator. *Economic Theory* 10, 1991, s. 29-52.
- MALKIEL, B. *Efficient Market Hypothesis*. New Palgrave Dictionary of Money and Finance. London: Macmillan, 1992.
- NELSON, D. B. Conditional Heteroskedasticity in Asset Returns: a New Approach. *Econometrica* 59, 1991, s. 347-370.
- PAGAN, A. R.; SCHWERT, G. W. Alternative Models for Conditional Stock Volatility. *Journal of Econometrics* 45, 1990, s. 267-290.
- POLÁČEK, J. *Základy kapitálových trhů*. Ostrava: VŠB-TU Ostrava, 2006. 168 s. ISBN 80-248-1046-8.
- RUBLÍKOVÁ, E. *Analýza vybraných časových radov – ARIMA modely*. 1. vyd. Bratislava: EKONÓM, 2008. 216 s. ISBN 978-80-225-2540-4.
- SENTANA, E. Quadratic ARCH Models. *Review of Economic Studies* 62, 1995, s. 639-661.
- ŠTĚRBA, F. Modely typu ARCH a jejich využití k modelování volatility měnových kurzů. *STATISTIKA*, 2007, č. 3.
- WEISS, A. A. ARMA Models with ARCH Errors. *Journal of Time Series Analysis* 5, 1984, s. 129-143.

Seznam zkratek

AC – autokorelační funkce

ADF – rozšířený Dickey-Fullerův test

AIC – Akaikeho informační kritérium

BCPB – Burza cenných papírů Bratislava

BCPP – Burza cenných papírů Praha

BSE – Budapest Stock Exchange (Burza cenných papírů v Budapešti)

CP – cenný papír

ČR – Česká republika

DF – Dickey-Fullerův test

EBOS – Elektronický burzovní obchodní systém

FESE – Federation of European Securities Exchanges (Federace evropských burz)

GPW – Gielda papierów wartościowych w Warszawie (Burza cenných papírů ve Varšavě)

HDP – hrubý domácí produkt

IPO – Initial Public Offering (počáteční veřejná nabídka)

LM – Lagrangeův multiplikátor

MTF – Multilateral Trading Facility (mnohostranný obchodní systém)

NBS – Národní banka Slovenska

NIC – News Impact Curve (křivka dopadu novinek)

PAC – parciální autokorelační funkce

SC – Schwartzovo informační kritérium

SPAD – Systém pro podporu trhu akcií a dluhopisů

Prohlášení o využití výsledků diplomové práce

Prohlašuji, že

- jsem byl seznámen s tím, že na mou diplomovou práci se plně vztahuje zákon č. 121/2000 Sb. – autorský zákon, zejména § 35 – užití díla v rámci občanských a náboženských obřadů, v rámci školních představení a užití díla školního a § 60 – školní dílo;
- beru na vědomí, že Vysoká škola báňská – Technická univerzita Ostrava (dále jen VŠB-TUO) má právo nevýdělečně, ke své vnitřní potřebě, diplomovou práci užít (§ 35 odst. 3);
- souhlasím s tím, že diplomová práce bude v elektronické podobě archivována v Ústřední knihovně VŠB-TUO a jeden výtisk bude uložen u vedoucího diplomové práce. Souhlasím s tím, že bibliografické údaje o diplomové práci budou zveřejněny v informačním systému VŠB-TUO;
- bylo sjednáno, že s VŠB-TUO, v případě zájmu z její strany, uzavřu licenční smlouvu s oprávněním užít dílo v rozsahu § 12 odst. 4 autorského zákona;
- bylo sjednáno, že užít své dílo, diplomovou práci, nebo poskytnout licenci k jejímu využití mohu jen se souhlasem VŠB-TUO, která je oprávněna v takovém případě ode mne požadovat přiměřený příspěvek na úhradu nákladů, které byly VŠB-TUO na vytvoření díla vynaloženy (až do jejich skutečné výše).

V Ostravě dne 14. dubna 2010

.....
Bc. Michal Mazur

Adresa trvalého pobytu studenta:

Konská 12, 739 61 Třinec, okr. Frýdek-Místek

Přílohy

Příloha č.1: Báze indexu WIG